



TUGAS AKHIR - SS 141501

PEMODELAN *VECTOR AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION* (VAR-SVR) DAN *GENERALIZED SPACE TIME AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION* (GSTAR-SVR) UNTUK PERAMALAN CURAH HUJAN DI KOTA SURABAYA

FEBY SANDI NABILA
NRP 1312100 072

Dosen Pembimbing
Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si

Program Studi S1 Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2016



FINAL PROJECT - SS 141501

MODELLING *AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION* (VAR-SVR) AND *GENERALIZED SPACE TIME AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION* (GSTAR-SVR) FOR RAINFALL FORECASTING IN SURABAYA.

FEBY SANDI NABILA
NRP 1312100 072

Supervisor
Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si

Undergraduate Programme of Statistics
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2016

LEMBAR PENGESAHAN

**PEMODELAN VECTOR AUTOREGRESSIVE - SUPPORT
VECTOR REGRESSION (VAR-SVR) DAN GENERALIZED
SPACE TIME AUTOREGRESSIVE - SUPPORT VECTOR
REGRESSION (GSTAR-SVR) UNTUK PERAMALAN
CURAH HUJAN DI KOTA SURABAYA**

TUGAS AKHIR

**Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada**

**Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember**

Oleh :

**FEBY SANDI NABILA
NRP. 1312 100 072**

Disetujui oleh Pembimbing Tugas Akhir :

**Dr. rer. pol. Dedy Dwi Prastyo
NIP. 19831204 200812 1002**

()

**Mengetahui
Ketua Jurusan Statistika FMIPA-ITS**


**Dr. Suhartono
NIP. 19710929 199512 1 001**

SURABAYA, JANUARI 2016

STATISTIKA

PEMODELAN VECTOR AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION (VAR-SVR) DAN GENERALIZED SPACE TIME AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION (GSTAR-SVR) UNTUK PERAMALAN CURAH HUJAN DI KOTA SURABAYA

Nama Mahasiswa : Feby Sandi Nabila

NRP : 1312 100 072

Jurusan : Statistika

**Dosen Pembimbing: Dr. rer. pol. Dedy Dwi Prastyo,
S.Si.,M.Si**

Abstrak

Pemanasan global pada abad ini memicu terjadinya perubahan iklim dan berpotensi mengubah pola cuaca secara ekstrem diberbagai Negara tak terkecuali di Indonesia. Keadaan alam yang semakin terganggu membuat curah hujan di setiap wilayah semakin sulit untuk diprediksi. Surabaya yang memiliki peran penting sebagai pusat perekonomian di Jawa Timur khususnya dalam sektor pertanian menjadi salah satu kota yang perlu diprediksi keadaan curah hujannya agar sektor pertanian berjalan baik. Pemodelan untuk memprediksi curah hujan yang bersifat multivariate dan sering digunakan adalah Vector Autoregressive (VAR) dan metode pemodelan Generalized Space Time Autoregressive (GSTAR), suatu model yang dapat diterapkan pada data dengan variabel lokasi yang heterogen. Penelitian ini menggunakan Metode Pemodelan VAR-SVR dan GSTAR-SVR yang merupakan metode pemodelan time series parametrik dan non parametrik, dengan cara menggunakan variabel-variabel yang signifikan dari model VAR dan GSTAR sebagai variabel prediktor pada model SVR. Berdasarkan hasil yang diperoleh diketahui metode terbaik untuk memodelkan curah hujan di Surabaya adalah model VAR-SVR.

Kata kunci : Curah Hujan, VAR, GSTAR, SVR

(Halaman ini sengaja dikosongkan)

**MODELLING AUTOREGRESSIVE - SUPPORT VECTOR
REGRESSION (VAR-SVR) AND GENERALIZED SPACE TIME
AUTOREGRESSIVE - SUPPORT VECTOR REGRESSION
(GSTAR-SVR) FOR RAINFALL FORECASTING AT SURABAYA**

Name : Feby Sandi Nabila
NRP : 1312 100 072
Department : Statistics
Supervisor : Dr. rer. pol. Dedy Dwi Prastyo,
S.Si.,M.Si

Abstract

Global warming in this century triggering climate change and potentially to change weather patterns in various countries including in Indonesia. Natural conditions that increasingly disturbed make rainfall in any region increasingly difficult to predict. Surabaya, which has an important role as an economic center in East Java, especially in the agricultural sector into one of the towns that need to predict the state of the rainfall that the agricultural sector is going well. Modeling to predict the rainfall that often used is multivariate and Vector Autoregressive (VAR) and modeling methods Generalized Space Time Autoregressive (GSTAR), a model that can be applied to the data with the location of the heterogeneous variables. This study uses a VAR-SVR and GSTAR-SVR Modeling Method which is a methods of modeling time series of parametric and nonparametric, by using the significant variables of the VAR and GSTAR as predictor variables in the model SVR. Based on the results obtained the best method for modeling rainfall in Surabaya is a VAR-SVR model.

Keywords : Rainfall, VAR, GSTAR, SVR

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadiran Allah SWT, atas segala rahmat dan karunia-Nya yang tak pernah henti diberikan, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul **“Pemodelan Vector Autoregressive - Support Vector Regression (VAR-SVR) dan Generalized Space Time Autoregressive - Support Vector Regression (GSTAR-SVR) untuk Peramalan Curah Hujan di Kota Surabaya”** dengan baik. Penyusunan Tugas Akhir ini tidak luput dari bantuan serta dukungan dari berbagai pihak. Pada kesempatan ini, penulis ingin mengucapkan terima kasih yang kepada :

1. Bapak Dr. rer. pol. Dedy Dwi Prastyo, S.Si.,M.Si selaku dosen pembimbing yang telah memberikan ilmu, wawasan, dan nasihat yang berharga bagi penulis serta kesabaran dan kebaikan hati untuk membimbing dan selalu memberikan masukan dalam penyelesaian Tugas Akhir ini.
2. Bapak Dr. Brodjol Sutijo dan Ibu Dr. Irhamah, S.Si., M.Si selaku dosen penguji yang telah memberikan kritikan dan saran demi kesempurnaan Tugas Akhir.
3. Bapak Dr. Suhartono, M.Sc selaku Ketua Jurusan Statistika ITS yang telah menyediakan fasilitas guna kelancaran pengerjaan Tugas Akhir ini.
4. Ibu Dra. Lucia Aridinanti, MT selaku Ketua Program Studi Sarjana Jurusan Statistika ITS.
5. Bapak Prof. Nur Iriawan, MKom selaku dosen wali atas segala nasehat dan bimbingan yang berguna selama 7 semester pada saat perwalian.
6. Bapak Dr. Ardhasena Sopaheluwakan selaku pembimbing kerja praktek di BMKG Jakarta Pusat atas dukungan, bimbingan, dan saran dami kesempurnaan Tugas Akhir.
7. Ayah tercinta Sugeng Irianto, Ibu tersayang Dwi Puryani, Kakak tercantik Norma Meyricha Sandi Pratiwi, dan Adik terganteng Yafi Sandi Hardin terima kasih atas doa, nasehat,

dan kasih sayang yang sangat besar yang telah diberikan untuk penulis sehingga dapat menjadi motivasi dan penyemangat bagi penulis disaat menghadapi kesulitan :').

8. Teman-teman seperjuangan Statistika ITS $\Sigma 23$ yang memberikan hangatnya sebuah kebersamaan dan rasa kekeluargaan selama 3,5 tahun ini.
9. Serta semua pihak yang telah memberikan dukungan baik moril maupun materiil yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari masih banyaknya kekurangan dalam pembuatan laporan Tugas Akhir ini, besar harapan bagi penulis untuk dapat menerima saran dan kritik yang bersifat membangun guna perbaikan di masa mendatang. Semoga laporan Tugas Akhir ini dapat bermanfaat bagi penelitian selanjutnya.

Surabaya, Januari 2016

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITLE PAGE	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xv
DAFTAR GAMBAR	xix
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
1.5 Batasan Masalah.....	6
BAB II TINJAUAN PUSTAKA	
2.1 Statistika Deskriptif.....	7
2.2 Analisis <i>Multivariate Time Series</i>	7
2.2.1 Stasioneritas	7
2.3 VAR (<i>Vector Autoregressive</i>)	8
2.3.1 Identifikasi Model.....	10
2.3.2 Estimasi Parameter Model VAR.....	14
2.3.3 Pemeriksaan Diagnostik Model VAR.....	15
2.4 GSTAR (<i>Generalized Space Time Autoregressive</i>)	18
2.4.1 Pemilihan Bobot Lokasi pada Model GSTAR ..	19
2.4.2 Estimasi Parameter Model GSTAR	22
2.5 Peramalan Model <i>Multivariate Time Series</i>	22
2.6 SVR (<i>Support Vector Regression</i>).....	23
2.7 Pemilihan Model Terbaik	30
2.8 Curah Hujan.....	31
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data dan Variabel Penelitian	33

3.2	Metode Analisis.....	33
3.3	Diagram Alir	36
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Statsitika Deskriptif.....	37
4.1.1	Statsitika Deskriptif Perak 1	39
4.1.2	Statsitika Deskriptif Perak 1	47
4.1.3	Statsitika Deskriptif Juanda.....	55
4.2	Pemodelan VAR.....	63
4.2.1	Identifikasi Orde Model VAR	63
4.2.2	Estimasi Parameter Model VAR	67
4.2.3	Peramalan Model VAR	78
4.2.4	Pengujian Asumsi Residual <i>White Noise</i>	81
4.2.5	Pengujian Multivariat Normal	82
4.2.6	Pemilihan Model VAR Terbaik.....	83
4.3	Pemodelan VAR-SVR.....	87
4.3.1	Pemodelan VAR-SVR Perak 1	88
4.3.2	Pemodelan VAR-SVR Perak 2.....	90
4.3.3	Pemodelan VAR-SVR Juanda.....	92
4.4	Pemodelan GSTAR	94
4.4.1	Penaksiran Parameter Bobot Seragam.....	96
4.4.2	Penaksiran Parameter Bobot Invers Jarak	101
4.4.3	Penaksiran Parameter Bobot Normalisasi Korelasi Silang	106
4.4.4	Peramalan Model GSTAR.....	111
4.4.5	Pengujian Asumsi Residual <i>White Noise</i>	123
4.4.6	Pengujian Multivariat Normal	124
4.4.7	Pemilihan Model GSTAR Terbaik	125
4.5	Pemodelan GSTAR-SVR	129
4.5.1	Pemodelan GSTAR-SVR Perak 1	130
4.5.2	Pemodelan GSTAR-SVR Perak 2	132
4.5.3	Pemodelan GSTAR-SVR Juanda	134
4.6	Peramalan Satu Tahun Kedepan.....	136
4.6.1	Peramalan Model VAR	136
4.6.2	Peramalan Model GSTAR.....	137
4.6.3	Peramalan Model VAR-SVR	138

4.6.4 Peramalan Model GSTAR-SVR.....	140
BAB V KESIMPULAN DAN SARAN	
5.1 Kesimpulan.....	143
5.2 Saran.....	144
DAFTAR PUSTAKA	145
LAMPIRAN	149

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1 Contoh Nilai MCCF.....	11
Tabel 2.2 Contoh Nilai MPCCF.....	13
Tabel 3.1 Struktur Data	33
Tabel 4.1 Statistika Deskriptif Curah Hujan Dasarian	37
Tabel 4.2 Statistika Deskriptif Data Curah Hujan Dasarian di Perak 1	39
Tabel 4.3 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 1.....	43
Tabel 4.4 Statistika Deskriptif Data Curah Hujan Dasarian di Perak 2	47
Tabel 4.5 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 2.....	51
Tabel 4.6 Statistika Deskriptif Data Curah Hujan Dasarian di Juanda	55
Tabel 4.7 Statistika Deskriptif Data Curah Hujan Dasarian di Juanda	59
Tabel 4.8 Hasil Estimasi Parameter Model VARIMA (2,0,0) (1,1,0) ³⁶	68
Tabel 4.9 Hasil Estimasi Parameter Model VARIMA (2,0,0) (2,1,0) ³⁶	70
Tabel 4.10 Hasil Estimasi Parameter Model VARIMA (2,0,0) (3,1,0) ³⁶	71
Tabel 4.11 Hasil Etimasi Parameter Model VARIMA (2,0,0) (4,1,0) ³⁶	74
Tabel 4.12 Hasil Estimasi Parameter Model VARIMA (2,0,0) (5,1,0) ³⁶	76
Tabel 4.13 Hasil Pengujian Portmanteau	81
Tabel 4.14 P-value Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Shapiro Wilk.....	83
Tabel 4.15 Perbandingan Nilai RMSE Out-sample Model VAR	84

Tabel 4.15	Perbandingan Nilai RMSE In-sample Model VAR	84
Tabel 4.16	Perbandingan Nilai AIC Model VAR	85
Tabel 4.17	Hasil Pencarian RMSE Terkecil untuk Perak 1	88
Tabel 4.18	Hasil Pencarian RMSE Terkecil untuk Perak 2	90
Tabel 4.19	Hasil Pencarian RMSE Terkecil untuk Juanda	92
Tabel 4.19	AIC Residual dari Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶	95
Tabel 4.20	Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Seragam	99
Tabel 4.21	Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Invers Jarak	104
Tabel 4.22	Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Normalisasi Korelasi Silang	108
Tabel 4.23	AIC Residual dari Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶ Menggunakan Semua Parameter	122
Tabel 4.24	AIC Residual dari Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶ Menggunakan Parameter Signifikan	123
Tabel 4.25	P-value Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Semua Parameter	124
Tabel 4.26	P-value Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Parameter Signifikan	125
Tabel 4.27	Perbandingan Nilai RMSE In-sample dari Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶	126
Tabel 4.28	Perbandingan Nilai RMSE Out-sample dari Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶	126

Tabel 4.29	Perbandingan Nilai AIC Model GSTAR ([1,2,36,72,108,144,180]1)-I(1) ³⁶	127
Tabel 4.30	Hasil Pencarian RMSE Terkecil untuk Perak 1 ..	130
Tabel 4.31	Hasil Pencarian RMSE Terkecil untuk Perak 2 ..	132
Tabel 4.32	Hasil Pencarian RMSE Terkecil untuk Juanda ...	134

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Contoh Plot MCCF dengan Tiga Data Time Series.....	12
Gambar 2.2 Contoh Plot MPCCF dengan Tiga Data Time Series	13
Gambar 2.3 Contoh Peta Lokasi.....	20
Gambar 2.4 Batas Keputusan untuk Set Data.....	25
Gambar 2.5 Batas <i>Error</i> dalam SVR.....	26
Gambar 3.1 Diagram Alir Penelitian.....	36
Gambar 4.1 <i>Box Plot</i> Akumulasi Data Curah Hujan Perdasarian di Perak 1.....	42
Gambar 4.2 <i>Box Plot</i> Data Curah Hujan Tahunan di Perak 1	46
Gambar 4.3 <i>Box Plot</i> Akumulasi Data Curah Hujan Perdasarian di Perak 2.....	50
Gambar 4.4 <i>Box Plot</i> Data Curah Hujan Tahunan di Perak 2	54
Gambar 4.5 <i>Box Plot</i> Akumulasi Data Curah Hujan Perdasarian di Juanda.....	58
Gambar 4.6 <i>Box Plot</i> Data Curah Hujan Tahunan di Juanda	62
Gambar 4.7 MCCF Plot Data Curah Hujan di Ketiga Lokasi	64
Gambar 4.8 ACF Plot Data Curah Hujan di (a) Perak 1, (b) Perak 2, (c) Juanda	65
Gambar 4.9 MCCF Plot Data Curah Hujan Setelah <i>Differencing</i> 36	65
Gambar 4.10 MPCCF Plot Data Curah Hujan yang Sudah Stasioner.....	66
Gambar 4.11 <i>Time Series Plot</i> Hasil Peramalan pada Data <i>In-sample</i> untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.....	79

Gambar 4.12	<i>Time Series Plot</i> Hasil Peramalan pada Data <i>Out-sample</i> untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.....	80
Gambar 4.13	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Perak 1 pada Data <i>in-sample</i>	89
Gambar 4.14	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Perak 1 pada Data <i>out-sample</i>	90
Gambar 4.15	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Perak 2 pada Data <i>in-sample</i>	91
Gambar 4.16	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Perak 2 pada Data <i>out-sample</i>	92
Gambar 4.17	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Juanda pada Data <i>in-sample</i>	93
Gambar 4.18	<i>Time Series Plot</i> Hasil Peramalan Model VAR-SVR Juanda pada Data <i>out-sample</i>	94
Gambar 4.19	Jarak Antar Lokasi Pencatatan Curah Hujan	102
Gambar 4.20	<i>Time Series Plot</i> Hasil Peramalan data <i>In-sample</i> Model GSTAR di Perak 1 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.....	112
Gambar 4.21	<i>Time Series Plot</i> Hasil Peramalan Model GSTAR di Perak 1 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.	113
Gambar 4.22	<i>Time Series Plot</i> Hasil Peramalan data <i>In-sample</i> Model GSTAR di Perak 2 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.....	116
Gambar 4.23	<i>Time Series Plot</i> Hasil Peramalan Data <i>Out-Sample</i> Model GSTAR di Perak 2 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.....	117
Gambar 4.24	<i>Time Series Plot</i> Hasil Peramalan data <i>In-sample</i> Model GSTAR di Juanda	

	Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.....	119
Gambar 4.25	<i>Time Series Plot</i> Hasil Peramalan Model GSTAR di Juanda Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.	121
Gambar 4.26	<i>Time Series</i> Hasil Peramalan Model GSTAR-SVR Perak 1.....	131
Gambar 4.27	<i>Time Series Plot</i> Hasil Peramalan pada Data <i>out-sample</i> Model GSTAR-SVR Perak 1.....	131
Gambar 4.28	<i>Time Series Plot</i> Hasil Peramalan Data <i>In-sample</i> Model GSTAR-SVR Perak 2	133
Gambar 4.29	<i>Time Series Plot</i> Hasil Peramalan pada Data <i>out-sample</i> Model GSTAR-SVR Perak 2.....	133
Gambar 4.30	<i>Time Series Plot</i> Hasil Peramalan pada Data <i>In-sample</i> Model GSTAR-SVR Juanda.....	135
Gambar 4.31	<i>Time Series Plot</i> Hasil Peramalan pada Data <i>out-sample</i> Model GSTAR-SVR Juanda.....	135
Gambar 4.32	Hasil Peramalan pada Model VAR untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.....	137
Gambar 4.33	Hasil Peramalan pada Model <i>gstAR</i> untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.....	138
Gambar 4.34	Hasil Peramalan pada Model VAR-SVR untuk Lokasi (a)Perak 1; (b) Perak 2; (c) Juanda.....	139
Gambar 4.35	Hasil Peramalan pada Model GSTAR-SVR untuk Lokasi (a)Perak 1; (b) Perak 2; (c) Juanda.	141

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1	Data Akumulasi Curah Hujan Dasarian di Lokasi Perak 1, Perak 2, Juanda 149
Lampiran 2	<i>Matrix Partial Cross Correlation Function</i> 150
Lampiran 3	Estimasi Parameter Model VARIMA (2,0,0)(1,1,0) ³⁶ Sebelum dilakukan <i>Restrict</i> 151
Lampiran 4	Program SAS Model VARIMA (2,0,0)(1,1,0) ³⁶ 152
Lampiran 5	Program untuk Model VAR-SVR di Perak 1 dengan R..... 153
Lampiran 6	Program untuk Model GSTAR-SVR Perak 1 dengan R..... 156
Lampiran 7	Program SAS untuk Model GSTAR Bobot Seragam dengan Semua Parameter ... 159
Lampiran 8	Program SAS untuk Model GSTAR Bobot Seragam dengan Parameter Signifikan 160
Lampiran 9	Hasil Estimasi Model GSTAR Bobot Seragam dengan Semua Parameter..... 161
Lampiran 10	Hasil Estimasi Model GSTAR Bobot Seragam dengan Parameter Signifikan..... 163
Lampiran 11	Output Uji Normalitas Model VAR..... 164
Lampiran 12	Output Uji Normalitas Model GSTAR dengan Parameter Signifikan..... 165
Lampiran 13	Data untuk Model VAR-SVR di Perak 1 Keseluruhan 166
Lampiran 14	Data untuk Model GSTAR-SVR di Perak 1 Keseluruhan 167

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan salah satu negara yang secara geografis dilewati garis khatulistiwa. Posisi ini menjadikan Indonesia sebagai daerah pertemuan sirkulasi meridional (Utara-Selatan), yang dikenal sebagai sirkulasi *Hadley*, dan sirkulasi zonal (Timur-Barat) yang dikenal sebagai sirkulasi *Walker*. Dua sirkulasi tersebut sangat mempengaruhi keragaman iklim di Indonesia (Saputro, 2009). Dewasa ini naiknya aktivitas manusia yang sejalan dengan meningkatnya konsentrasi rumah kaca di atmosfer menyebabkan naiknya temperatur udara yang mencapai 1°C sampai dengan 3°C, peningkatan temperatur ini terjadi pada periode tahun 1985 sampai dengan tahun 2012 yang terjadi di Surabaya. Fenomena alam ini sering disebut dengan pemanasan global (*Global Warming*). Pemanasan global pada abad ini memicu terjadinya perubahan iklim dan berpotensi mengubah pola cuaca secara ekstrem diberbagai Negara tak terkecuali di Indonesia.

Pemanasan global mempengaruhi terjadinya perubahan iklim yang terlihat dari curah hujan dibawah normal (Saputro, 2009). Sebagai Negara tropis, Indonesia memiliki pola hujan yang sangat beragam dan memiliki curah hujan yang berbeda di setiap wilayah. Keadaan alam yang semakin terganggu membuat curah hujan di setiap wilayah semakin sulit untuk diprediksi. Seperti halnya di Surabaya, Surabaya yang memiliki peran penting sebagai pusat perekonomian di Jawa Timur khususnya dalam sektor pertanian menjadi salah satu kota yang perlu diprediksi keadaan curah hujannya agar sektor pertanian berjalan baik. Perubahan iklim yang dipicu oleh pemanasan global membuat pola hujan tidak menentu. Menurut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) suhu panas di kota pahlawan diperkirakan mencapai puncaknya sejak awal Oktober

2011 (Machmudin dan Ulama, 2012). Fakta ini menunjukkan bahwa Surabaya merupakan salah satu wilayah yang mengalami perubahan iklim sebagai akibat dari pemanasan global.

Penelitian-penelitian yang telah dilakukan menyebutkan variabel terpenting mengenai dampak perubahan iklim yang sering kali digunakan adalah curah hujan. Curah hujan mempunyai keragaman yang besar, baik dalam skala ruang maupun dalam skala waktu. Salah satu pemodelan *time series* yang banyak digunakan untuk data curah hujan adalah *Autoregressive Integrated Moving Average* (ARIMA). Namun, metode tersebut hanya digunakan pada pendugaan curah hujan berdasarkan data curah hujan yang ada di stasiun pengamatan (*temporal*) tanpa memperhatikan pengaruh pada lokasi stasiunnya (*spatial*). Selain itu model ARIMA juga bersifat *univariate*. Sehingga tidak dapat digunakan untuk data curah hujan yang bersifat *multivariate*. Oleh karena itu perlu diterapkan pemodelan yang sesuai untuk memprediksi curah hujan yang bersifat *multivariate* dan mempunyai keragaman yang besar baik dalam skala ruang maupun skala waktu.

Suatu model yang pernah dilakukan dalam penelitian sebelumnya yaitu *Vector Autoregressive Moving Average* (VARMA), yang merupakan perluasan dari model ARMA. Model ini menjelaskan keterkaitan antar pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya (Wutsqa dan Suhartono, 2009). Wutsqa dan Suhartono (2009) menerapkan metode pemodelan ini pada data pariwisata dengan membandingkan model VARMA dengan model VAR-GSTAR.

Hasil perbandingan menunjukkan bahwa secara prosedural model VARMA mempunyai kelemahan, karena tidak dapat mengakomodasi lag-lag *seasonal* pada orde model dan penelitian tersebut menyebutkan bahwa interpretasi terhadap model VAR-GSTAR memberikan hasil yang lebih realistis (Wutsqa dan Suhartono, 2009). Data deret waktu yang mempunyai pola

seasonal selain data pariwisata adalah data hidrologi seperti curah hujan, maka dari itu untuk pengolahan data curah hujan pada penelitian ini digunakan model *Vector Autoregressive* (VAR) yang merupakan pemodelan *time series* yang bersifat *multivariate* dan merupakan model yang tidak melibatkan faktor lokasi, data curah hujan yang memiliki keragaman yang besar pada skala ruang dan skala waktu membutuhkan suatu metode pemodelan yang memperhatikan faktor lokasi, sehingga pada penelitian ini juga digunakan metode pemodelan *Generalized Space Time Autoregressive* (GSTAR), suatu model yang dapat diterapkan pada data dengan variabel lokasi yang heterogen, dengan pemberian bobot untuk masing-masing lokasi. Fathiatul husna pada tahun 2013 telah melakukan pemodelan pada data inflasi di Jabodetabek menggunakan GSTAR dengan memberikan 4 jenis bobot lokasi yaitu bobot seragam, bobot invers jarak, bobot normalisasi silang, dan biner. Pada penelitian tersebut dihasilkan bahwa bobot terbaik yang sesuai untuk memodelkan inflasi adalah bobot invers jarak, namun hasil peramalan menunjukkan bahwa data hasil peramalan memiliki selisih yang berbeda jauh dengan nilai aktualnya, sehingga model GSTAR kurang sesuai untuk diterapkan pada data inflasi.

Penerapan model VAR dan GSTAR telah dilakukan oleh Diani pada tahun 2013 untuk memprediksi curah hujan di kabupaten Malang dengan menambahkan metode NN (*Neural Network*) sebagai suatu metode peramalan *time series* yang bersifat non linier. Hasil penelitian tersebut menyimpulkan bahwa hasil peramalan menggunakan VAR-NN lebih baik dari pada GSTAR-NN. Prediksi untuk data *time series* dibedakan menjadi dua yaitu dengan pendekatan linier dan non linier, selain menggunakan metode NN prediksi data *time series* dengan pendekatan non linier juga bisa dilakukan dengan menggunakan *Support Vector Machine* (SVM).

SVM merupakan pendekatan metode non linier yang berbasis *machine learning*. Pada awalnya SVM dikembangkan untuk kasus klasifikasi (Santosa, 2007). Salah satu modifikasi SVM

yang digunakan untuk pendekatan regresi adalah *Support Vector Regression* (SVR). Yasin, Prahutama, dan Utami pada tahun 2014 menerapkan metode SVR untuk memprediksi harga saham dengan menggunakan algoritma *grid search* didapatkan hasil prediksi untuk data training mempunyai akurasi yang lebih tinggi dibandingkan dengan prediksi untuk data testing. Selain itu ada juga Maharesi pada tahun 2013 yang menggunakan metode SVR pada prediksi return saham syariah BEI, yang membuktikan bahwa metode SVR merupakan model yang lebih baik dari pada regresi linier OLS.

Konsep dari SVR adalah memaksimalkan *hyperplane* untuk mendapatkan data-data yang menjadi *support vector*. Keunggulan SVR salah satunya adalah mampu mengatasi *overfitting* (Yasin, Prahutama, Utami 2014). Data curah hujan di tiga stasiun wilayah Surabaya merupakan data *seasonal* yang tidak dapat dijelaskan dengan tepat dengan pemodelan yang bersifat linier, *series* pada curah hujan dapat diprediksi dengan tepat apabila menggunakan pemodelan yang bersifat non linier. Maka dari itu untuk memodelkan curah hujan di tiga stasiun wilayah Surabaya dilakukan dengan suatu pendekatan model yang bersifat non linier.

Metode pemodelan non linier yang digunakan dalam kasus ini adalah *Support Vector Regression* (SVR). Penelitian ini menggunakan Metode Pemodelan VAR-SVR dan GSTAR-SVR yang merupakan kombinasi metode terbaru yakni dengan menggunakan variabel-variabel dengan lag yang signifikan pada model VAR dan GSTAR sebagai variabel prediktor dalam SVR. Berdasarkan hasil yang nantinya diperoleh dapat diketahui metode mana yang terbaik untuk memodelkan curah hujan di tiga stasiun wilayah Surabaya berdasarkan kriteria *root mean square of error* (RMSE) hasil peramalan.

1.2 Rumusan Masalah

Pemanasan global pada abad ini memicu terjadinya perubahan iklim dan berpotensi mengubah pola cuaca secara

ekstrem diberbagai negara tak terkecuali di Indonesia. Keadaan alam yang semakin terganggu membuat curah hujan di setiap wilayah semakin sulit untuk diprediksi. variabel terpenting mengenai dampak perubahan iklim yang sering kali digunakan adalah curah hujan, disisi lain Surabaya merupakan salah satu kota yang memiliki peran penting sebagai pusat perekonomian di Jawa Timur khususnya dalam sektor pertanian, sehingga Surabaya menjadi salah satu kota yang perlu diprediksi keadaan curah hujannya agar sektor pertanian berjalan baik. Kondisi curah hujan yang mempunyai keragaman yang besar, baik dalam skala ruang maupun dalam skala waktu dibutuhkan suatu metode yang tepat untuk memprediksi curah hujan di Kota Surabaya. Berdasarkan sifat data curah hujan tersebut dapat dirumuskan beberapa permasalahan yang terdapat pada penelitian kali ini adalah sebagai berikut.

1. Bagaimana model yang sesuai untuk meramalkan curah hujan di tiga stasiun wilayah Surabaya menggunakan pemodelan VAR?
2. Bagaimana model GSTAR yang terbaik untuk meramalkan curah hujan di tiga stasiun wilayah Surabaya?
3. Bagaimana model terbaik untuk meramalkan curah hujan di tiga stasiun wilayah Surabaya menggunakan pemodelan VAR-SVR dan GSTAR-SVR?
4. Bagaimana akurasi pemodelan VAR-SVR dan GSTAR-SVR dalam memprediksikan curah hujan di tiga stasiun wilayah Surabaya?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan yang ingin diperoleh dari penelitian adalah sebagai berikut.

1. Mendapatkan model yang sesuai untuk peramalan curah hujan di tiga stasiun wilayah Surabaya dengan pemodelan VAR.
2. Mendapatkan bentuk model GSTAR yang sesuai untuk meramalkan curah hujan di tiga stasiun wilayah Surabaya.

3. Memperoleh model terbaik untuk meramalkan curah hujan di tiga stasiun wilayah Surabaya menggunakan pemodelan VAR-SVR dan GSTAR-SVR.
4. Mengetahui keakuratan dalam memprediksi curah hujan di tiga stasiun wilayah Surabaya pada model VAR-SVR dan GSTAR-SVR.

1.4 Manfaat Penelitian

Manfaat yang akan diperoleh dari penelitian ini adalah sebagai berikut.

1. Menghasilkan model terbaik untuk meramalkan curah hujan di Surabaya dari 3 lokasi stasiun yang berbeda menggunakan VAR-SVR dan GSTAR-SVR.
2. Memberikan tambahan informasi sebagai bahan pertimbangan masa tanam bagi petani di Surabaya dimasa mendatang.
3. Menambah wawasan keilmuan statistika sebagai pengembangan dari penerapan metode VAR-SVR dan GSTAR-SVR dalam bidang komputasi.
4. Hasil penelitian dapat digunakan sebagai bahan referensi bagi penelitian-penelitian selanjutnya.

1.5 Batasan Penelitian

Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Penelitian tugas akhir ini dilakukan hanya pada 3 lokasi stasiun pengamatan yang berbeda karena berbagai pertimbangan.
2. *Series* waktu untuk setiap stasiun pengamatan adalah selama 32 tahun.
3. Asumsi *white noise* dari residual oleh model VAR dan GSTAR terpenuhi.

BAB II

TINJAUAN PUSTAKA

2.1 Statistika Deskriptif

Statistika deskriptif adalah bagian dari ilmu statistika yang merupakan sekelompok metode statistika untuk pengumpulan dan penyajian data sehingga menghasilkan suatu informasi yang berguna (Walpole, 1995). Ukuran yang sering digunakan untuk memberikan informasi mengenai data adalah ukuran pemusatan data dan ukuran penyebaran data yang digunakan untuk mendefinisikan ukuran numerik untuk menjelaskan karakteristik gugus data. Ukuran pemusatan data meliputi *mean*, median, dan modus. Sedangkan ukuran penyebaran data meliputi range, ragam, dan simpangan baku.

2.2 Analisis *Multivariate Time Series*

Analisis *time series* adalah salah satu metode peramalan secara matematis dengan menggunakan waktu sebagai acuan, kemudian membuat prediksi dengan menggunakan ekstrapolasi berdasarkan waktu untuk pola-pola tersebut (Muhtaram, 2011). Beberapa kasus penelitian yang telah berkembang memerlukan suatu analisis *time series* yang mempertimbangkan berbagai *time series* secara simultan, analisis ini disebut dengan analisis *multivariate time series* (Tsay, 2014).

2.2.1 Stasioneritas

Data stasioner adalah data runtun waktu yang paling sederhana dan sangat bermanfaat untuk menjelaskan beragam jenis analisis runtun waktu lainnya. Menurut Box-jenkins, *time series* yang bersifat stasioner memiliki *mean* (μ), varians (σ^2), dan kovarians (τ_k) tidak berpengaruh oleh pengamatan. Adapun tidak stasioner dalam *time series* ada dua macam yaitu tidak stasioner dalam *mean* dan tidak stasioner dalam varians.

1. Stasioner dalam *mean*

Data runtun waktu dikatakan rtasioner dalam *mean*, jika $E(Y_t) = \mu$ yang artinya nilai *mean* konstan terhadap waktu. *Time series* yang tidak stasioner dalam *mean* yang berarti $E(y_t)$ dipengaruhi oleh waktu pengamatan yaitu $E(Y_t) = \mu_t$. Untuk mengatasi *time series* yang tidak stasioner dalam *mean* dapat dilakukan pembedaan atau sering disebut dengan *differencing*. *Differencing* data *time series* dapat dirumuskan seperti berikut:

$$W_t = Y_t - Y_{t-1}, \quad (2.1)$$

dengan:

W_t = *Differencing* orde ke-1
 t = Indeks waktu
 Y_t = Data pengamatan ke- t
 Y_{t-1} = Data pengamatan ke- $(t-1)$.

2. Stasioner dalam varians

Varians Y_t pada kasus data *time series* yang tidak stasioner akan berubah sejalan dengan perubahan level var $(Y_t) = \sigma_t = cf(\mu_t)$. Untuk konstan c yang positif dan fungsi f dibutuhkan transformasi $T(Y_t)$ yang memiliki varians konstan yang disebut sebagai transformasi varians. Pada umumnya untuk menstabilkan varians, digunakan transformasi *Box-Cox* (Wei, 2006):

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}, \quad (2.2)$$

dengan:

$T(Y_t)$ = Transformasi data ke- t
 t = Indeks waktu
 λ = Nilai koefisien dari transformasi *Box-Cox*.

2.3 VAR (*Vector Autoregressive*)

Model VAR sebenarnya merupakan gabungan dari beberapa model AR (*Autoregressive*), dimana model-model ini membentuk sebuah vektor yang antara variabel-variabelnya saling mempengaruhi (Sims, 1972). Model VAR(1) adalah model VAR

berorde 1, artinya variabel bebas dari model tersebut hanyalah satu nilai lag dari variabel tak bebasnya. Sebuah *multivariate time series* dikatakan sebuah model VAR proses dari orde 1 jika mengikuti persamaan berikut (Tsay, 2014):

$$\dot{Y}_t = \Phi_0 + \Phi \dot{Y}_{t-1} + \alpha_t, \quad (2.3)$$

dengan:

Φ_0 = Vektor Konstanta berukuran $m \times 1$

\dot{Y}_t = $Y_t - \mu$

μ = $E(Y_t)$

α_t = Vektor $m \times 1$ dari residual pada waktu ke- t

\dot{Y}_t = Vektor $m \times 1$ dari variabel pada waktu ke- t

\dot{Y}_{t-1} = Vektor $m \times 1$ dari variabel pada waktu ke- $(t - 1)$.

Model VAR(1) untuk data *time series* dengan 3 variabel dapat ditulis dalam bentuk matriks seperti berikut:

$$\begin{bmatrix} \dot{Y}_{1t} \\ \dot{Y}_{2t} \\ \dot{Y}_{3t} \end{bmatrix} = \begin{bmatrix} \Phi_{10} \\ \Phi_{20} \\ \Phi_{30} \end{bmatrix} + \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix} \begin{bmatrix} \dot{Y}_{1t-1} \\ \dot{Y}_{2t-1} \\ \dot{Y}_{3t-1} \end{bmatrix} + \begin{bmatrix} \alpha_{1t} \\ \alpha_{2t} \\ \alpha_{3t} \end{bmatrix},$$

dengan :

$$\dot{Y}_t = \begin{bmatrix} \dot{Y}_{1t} \\ \dot{Y}_{2t} \\ \dot{Y}_{3t} \end{bmatrix} ; \quad \Phi_0 = \begin{bmatrix} \Phi_{10} \\ \Phi_{20} \\ \Phi_{30} \end{bmatrix} ; \quad \Phi = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix} ; \quad \dot{Y}_{t-1} =$$

$$\begin{bmatrix} \dot{Y}_{1t-1} \\ \dot{Y}_{2t-1} \\ \dot{Y}_{3t-1} \end{bmatrix} ; \quad \alpha_t = \begin{bmatrix} \alpha_{1t} \\ \alpha_{2t} \\ \alpha_{3t} \end{bmatrix},$$

persamaan model VAR dengan orde p atau VAR(p) dapat ditulis sebagai berikut (Tsay, 2014):

$$\dot{Y}_t = \Phi_0 + \Phi_1 \dot{Y}_{t-1} + \dots + \Phi_p \dot{Y}_{t-p} + \alpha_t \quad p > 0, \quad (2.4)$$

dengan:

Φ_p = Matriks $m \times m$ dari parameter ke- p

\dot{Y}_{t-p} = Vektor $m \times 1$ dari variabel pada waktu ke- $(t - p)$.

persamaan (2.3) dapat dituliskan dalam bentuk matriks sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1t} \\ \dot{Y}_{2t} \\ \vdots \\ \dot{Y}_{mt} \end{bmatrix} = \begin{bmatrix} \Phi_{10} \\ \Phi_{20} \\ \vdots \\ \Phi_{m0} \end{bmatrix} + \begin{bmatrix} \Phi_{11}^1 & \Phi_{12}^1 & \dots & \Phi_{1m}^1 \\ \Phi_{21}^1 & \Phi_{22}^1 & \dots & \Phi_{2m}^1 \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_{m1}^1 & \Phi_{m2}^1 & \dots & \Phi_{mm}^1 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1t-1} \\ \dot{Y}_{2t-1} \\ \vdots \\ \dot{Y}_{mt-1} \end{bmatrix} + \dots \\ + \begin{bmatrix} \Phi_{11}^p & \Phi_{12}^p & \dots & \Phi_{1m}^p \\ \Phi_{21}^p & \Phi_{22}^p & \dots & \Phi_{2m}^p \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_{m1}^p & \Phi_{m2}^p & \dots & \Phi_{mm}^p \end{bmatrix} \begin{bmatrix} \dot{Y}_{1t-1} \\ \dot{Y}_{2t-1} \\ \vdots \\ \dot{Y}_{mt-1} \end{bmatrix} + \begin{bmatrix} \alpha_{1t} \\ \alpha_{2t} \\ \vdots \\ \alpha_{mt} \end{bmatrix},$$

dengan operator *back-shift* B , persamaan (2.4) dapat ditulis dengan persamaan seperti berikut:

$$(I - \Phi B - \dots - \Phi_p B^p) \dot{Y}_t = \Phi_0 + \alpha_t. \quad (2.5)$$

Nilai I adalah matriks identitas dengan ukuran $m \times m$ dimana m adalah banyak *series*. Ada dua asumsi penting yang harus diperhatikan dari data *time series* agar bisa dibentuk menjadi model VAR, yaitu stasioneritas, normalitas, dan *error* yang saling bebas.

2.3.1 Identifikasi Model

Model VAR merupakan bentuk model *multivariate time series* yang mempunyai teknik identifikasi model yang hampir sama dengan identifikasi model *time series* yang *univariate*. Identifikasi model VAR dilakukan dengan visualisasi pola dari MCCF (*matrix cross correlation function*) dan MPCCF (*matrix partial cross correlation function*). Identifikasi MCCF dan MPCCF dilakukan setelah data sudah stationer.

Pada *multivariate time series* identifikasi dilakukan menggunakan MCCF. Pada *series* $\{Y_{i,t}\}$ dengan $i = 1, 2, \dots, m$ dan $t = 1, 2, \dots, T$ dimana m menunjukkan banyak *series* dan T menunjukkan banyak observasi pada setiap *series*. Persamaan matriks korelasi silang sampel MCCF dapat dituliskan seperti berikut (Wei, 2006):

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)], \quad (2.6)$$

dengan $\hat{\rho}_{ij}(k)$ adalah persamaan matriks korelasi silang sampel untuk komponen *series* ke- i dan ke- j pada lag ke- k yang dinyatakan dalam persamaan berikut:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{T-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\left[\sum_{t=1}^T (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^T (Y_{j,t} - \bar{Y}_j)^2 \right]^{1/2}} \quad (2.7)$$

Persamaan (2.7) simbol \bar{Y}_i dan \bar{Y}_j menunjukkan rata-rata sampel dari komponen *series* yang bersesuaian untuk vektor proses yang stasioner. $\hat{\rho}_{ij}(k)$ adalah estimator yang berdistribusi normal asimtotik (Hannan,1970). Persamaan matriks korelasi silang sampel ini digunakan untuk menentukan orde dalam model *moving average* (MA). Bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Untuk mengatasinya, Tiao dan Box (1981) dalam Wei (2006) memperkenalkan sebuah metode yang sesuai untuk meringkas penjelasan korelasi silang sampel, yaitu dengan menggunakan symbol (+), (-), and (.) pada posisi (i, j) dari matriks korelasi silang pada sampel. Dengan symbol (+) menotasikan nilai yang lebih besar dari 2 kali estimasi standar *error* dan menunjukkan adanya hubungan korelasi positif, (-) menotasikan nilai yang kurang dari -2 kali estimasi standar *error* atau adanya hubungan korelasi negatif, dan (.) menotasikan nilai yang berada di antara ± 2 kali estimasi standar *error* yang artinya tidak terdapat hubungan korelasi.

Tabel 2.1 Contoh Nilai MCCF dengan Tiga Data *Time Series*

Lag	0			1			2		
Variabel	Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃
Y ₁	1	0.51	0.99	0.02	0.91	0.22	-0.14	-0.21	-0.19
Y ₂	0.51	1	0.65	0.11	0.13	0.09	-0.07	-0.13	-0.06
Y ₃	0.99	0.65	1	0.91	0.11	0.13	-0.20	0.32	-0.15

Tabel 2.1 menunjukkan hasil perhitungan nilai MCCF dari tiga data *time series* dengan batas ± 2 kali estimasi standar *error*,

nilai tersebut selanjutnya dinotasikan dalam bentuk symbol seperti pada Gambar 2.1.

Variable/ Lag	0	1	2	3	4	5	6
y1		+.
y2		.+.+.
y3		. .+.

Gambar 2.1 Contoh *Plot* MCCF dengan Tiga Data *Time Series*

Data *time series* dikatakan sudah stasioner apabila plot MCCF jarang menampilkan tanda (+) dan (-) dan sebagian besar simbol yang mendominasi adalah (.). Dalam *univariate time series*, persamaan autokorelasi parsial sangat penting untuk menentukan orde dalam model AR. Generalisasi dari konsep PACF kedalam bentuk vektor *time series* dilakukan oleh Tiao dan Box (1981) dalam Wei (1994), yang mendefinisikan matriks autoregresi parsial pada lag k dengan notasi $\wp(k)$. Bentuk $\wp(k)$ sama dengan $\Phi_{k,k}$ dalam regresi *multivariate*, sehingga persamaan untuk matriks autoregresi parsial dinyatakan dalam bentuk sebagai berikut (Wei, 2006):

$$\wp(k) = \begin{cases} \Gamma'(1)[\Gamma(0)]^{-1} & k = 1 \\ \{\Gamma'(k) - \mathbf{c}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k)\}^{-1} & k > 1, \\ \{\Gamma(0) - \mathbf{b}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k)\} & \end{cases} \quad (2.8)$$

dengan:

$$\Gamma(k) = \text{cov}(\mathbf{Y}_t, \mathbf{Y}_{t+k})$$

Apabila \mathbf{Y}_t merupakan proses VAR(p), maka $\wp(k)$ memiliki sifat khusus sebagai berikut:

$$\wp(k) = \begin{cases} \Phi_p, & k = p \\ 0, & k > p, \end{cases} \quad (2.9)$$

untuk $k \geq 2$, maka nilai $\mathbf{A}(k)$, $\mathbf{b}(k)$, dan $\mathbf{c}(k)$ adalah sebagai berikut:

$$\mathbf{A}(k) = \begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma'(k-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(k-2) & \Gamma(k-3) & \dots & \Gamma(0) \end{bmatrix};$$

$$\mathbf{b}(k) = \begin{bmatrix} \Gamma'(k-1) \\ \Gamma'(k-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}; \mathbf{c}(k) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{bmatrix},$$

seperti pada persamaan autokorelasi parsial pada data *univariate*, persamaan $\wp(k)$ juga memiliki *cut-off* untuk VAR. Begitu juga dengan nilai-nilai MPCCF yang juga dinotasikan dalam bentuk simbol (+), (-), dan (.) seperti pada MCCF. Contoh nilai-nilai hasil perhitungan MPCCF ditampilkan dalam Tabel 2.2.

Tabel 2.2 Contoh Nilai MPCCF dengan Tiga Data *Time Series*

Lag	0			1			2		
Variabel	Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃
Y ₁	-0.19	-0.05	0.30	-0.02	-0.91	0.08	0.14	-0.21	-0.19
Y ₂	0.51	0.78	-0.65	0.11	-0.31	0.09	0.07	-0.13	-0.02
Y ₃	0.99	0.65	-0.18	-0.91	-0.11	0.40	0.20	0.03	-0.15

Tiao dan Box (1981) dalam Wei (2006) juga mendefinisikan nilai MPCCF dengan menotasikan nilai-nilai MPCCF dalam bentuk symbol (+), (-), dan (.). Tanda (+) untuk nilai lebih besar dari $2\sqrt{T}$, tanda (-) untuk nilai kurang dari $-2\sqrt{T}$ dan tanda (.) untuk nilai yang berada diantara $-2\sqrt{T}$ dan $2\sqrt{T}$.

Variable/ Lag	1	2	3	4	5	6
y1	+
y2	..	+
y3	+	..	+	..

Gambar 2.2 Contoh *Plot* MPCCF dengan Tiga Data *Time Series*

Identifikasi Plot MPCCF sama dengan plot MCCF. Data *time series* dikatakan sudah stasioner apabila plot MPCCF jarang menampilkan tanda (+) dan (-) dan sebagian besar simbol yang mendominasi adalah (.).

2.3.2 Estimasi Parameter Model VAR

Estimasi parameter dilakukan dengan menggunakan metode *conditional least square*. Menggunakan data *time series* dengan banyak data sebanyak T untuk masing-masing *series* sebanyak m , maka model VAR(p) yang sudah dinyatakan stasioner dapat dituliskan sebagai berikut:

$$\mathbf{y}_t = \boldsymbol{\delta} + \sum_{i=1}^p \boldsymbol{\Phi}_i \mathbf{y}_{t-i} + \mathbf{a}_t, \quad (2.10)$$

dengan $\mathbf{y}_{t-p+1}, \dots, \mathbf{y}_0$ diasumsikan tersedia datanya untuk memudahkan dalam penotasian. Persamaan (2.10) dapat dinyatakan dalam bentuk umum model linier multivariat sebagai berikut:

$$\mathbf{Y} = \mathbf{XB} + \mathbf{A}, \quad (2.11)$$

atau
$$\mathbf{y} = (\mathbf{X}^T \otimes \mathbf{I}_m) \boldsymbol{\beta} + \mathbf{a}, \quad (2.12)$$

dengan:

\otimes = *kroncker product*

$\mathbf{Y} = (\mathbf{y}_1, \dots, \mathbf{y}_T)_{(m \times T)}$

$\mathbf{B} = (\boldsymbol{\delta}, \boldsymbol{\Phi}_1, \dots, \boldsymbol{\Phi}_p)_{(m \times (mp+1))}$

$\mathbf{X} = (\mathbf{X}_0, \dots, \mathbf{X}_t, \dots, \mathbf{X}_{T-1})_{((mp+1) \times T)}$

$\mathbf{X}_t = \begin{pmatrix} 1 \\ \mathbf{y}_t \\ \vdots \\ \mathbf{y}_{t-p+1} \end{pmatrix}_{((mp+1) \times 1)}$

$\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_T)_{(m \times T)}$

$\mathbf{y} = (\text{vec}(\mathbf{Y}))_{(mT \times 1)}$

$$\boldsymbol{\beta} = (\text{vec}(\mathbf{B}))_{((m^2 p + m) \times 1)}$$

$$\mathbf{a} = (\text{vec}(\mathbf{A}))_{(mT \times 1)}.$$

vec menyatakan operator *stacking* kolom. Sehingga estimasi parameter $\boldsymbol{\beta}$ dengan menggunakan *conditional least square* dapat dituliskan dalam persamaan berikut:

$$\hat{\boldsymbol{\beta}} = ((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \otimes \mathbf{I}_m)\mathbf{y}. \quad (2.13)$$

Sifat konsistensi dan asimtotik normalitas dari penaksir *conditional least square* $\hat{\boldsymbol{\beta}}$ adalah:

$$\sqrt{T}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \xrightarrow{d} N(0, \Gamma_p^{-1} \otimes \Sigma), \quad (2.14)$$

dimana $\mathbf{X}'\mathbf{X}/T$ konvergen dalam probabilitas menuju Γ_p dan \xrightarrow{d} menyatakan konvergen dalam distribusi. Penaksir untuk Σ adalah:

$$\hat{\Sigma} = (T - (mp + 1))^{-1} \sum_{t=1}^T \hat{\mathbf{a}}_t \hat{\mathbf{a}}_t', \quad (2.15)$$

dengan $\hat{\mathbf{a}}_t$ adalah vektor residual.

2.3.3 Pemeriksaan Diagnostik Model VAR

Estimasi parameter yang sudah diperoleh, selanjutnya kecukupan dari kesesuaian model harus diperiksa dengan analisis diagnosa dari residual sebagai berikut:

$$\hat{\mathbf{a}}_t = \dot{\mathbf{y}}_t - \hat{\boldsymbol{\Phi}}_1 \dot{\mathbf{y}}_{t-1} - \cdots - \hat{\boldsymbol{\Phi}}_p \dot{\mathbf{y}}_{t-p}, \quad (2.16)$$

dengan $\dot{\mathbf{y}}_t$ digunakan untuk menotasikan \mathbf{y}_t jika $\boldsymbol{\mu} = \mathbf{0}$ dan menotasikan $(\mathbf{y}_t - \hat{\boldsymbol{\mu}})$ dengan $\boldsymbol{\mu}$ merupakan vektor rata-rata, dan $\hat{\boldsymbol{\Phi}}_i$ adalah nilai taksiran dari parameter $\boldsymbol{\Phi}_i$. Suatu model *time series* dikatakan cukup jika residual model bersifat *white noise*. Maka dari itu matriks korelasi dari \mathbf{a}_t harus tidak signifikan dan tidak memiliki pola (Wei, 2006).

Pengujian residual *white noise* dilakukan dengan menggunakan uji *Multivariate portmanteau statistics*. Misalkan

\mathbf{R}_k menyatakan residual untuk lag k pada matrik korelasi silang. Dengan hipotesis sebagai berikut:

$$H_0: \mathbf{R}_1 = \dots = \mathbf{R}_s = \mathbf{0}$$

$$H_0: \mathbf{R}_j \neq \mathbf{0}.$$

Untuk $1 \leq j \leq s$. Dimana s bernilai positif integer sebelum ditetapkan. Persamaan statistik *portmanteau* secara *univariate* telah digeneralisasi oleh beberapa tokoh diantaranya Hosking (1980, 1981), Li dan McLeod (1981), dan Li (2004) untuk kasus multivariat sehingga didapatkan uji statistik Ljung-Box multivariat sebagai berikut (Tsay, 2014):

$$Q_{m(s)} = T^2 \sum_{k=1}^s \frac{1}{T-k} \text{tr}(\hat{\mathbf{\Gamma}}_k' \hat{\mathbf{\Gamma}}_0^{-1} \hat{\mathbf{\Gamma}}_k \hat{\mathbf{\Gamma}}_0^{-1}), \quad (2.17)$$

dengan:

m = banyak *series*

s = banyak lag yang diuji

T = banyak data.

dengan $\hat{\mathbf{\Gamma}}_k$ menunjukkan matriks *sample autocovariance* residual pada lag k yang dapat dituliskan sebagai berikut:

$$\hat{\mathbf{\Gamma}}_k = \frac{1}{T} \sum_{t=k+1}^T \mathbf{a}_t \mathbf{a}_{t-k}' . \quad (2.18)$$

Berdasarkan persamaan (2.17) statistik uji *Multivariate portmanteau statistics* yang digunakan untuk uji residual adalah sebagai berikut:

$$\begin{aligned} Q_{m(s)} &= T^2 \sum_{k=1}^s \frac{1}{T-k} \text{tr}(\hat{\mathbf{R}}_k' \hat{\mathbf{R}}_0^{-1} \hat{\mathbf{R}}_k \hat{\mathbf{R}}_0^{-1}) \\ &= T^2 \sum_{k=1}^s \frac{1}{T-k} \text{tr}(\hat{\mathbf{R}}_k' \hat{\mathbf{R}}_0^{-1} \hat{\mathbf{R}}_k \hat{\mathbf{R}}_0^{-1} \hat{\mathbf{D}}^{-1} \hat{\mathbf{D}}) \\ &= T^2 \sum_{k=1}^s \frac{1}{T-k} \text{tr}(\hat{\mathbf{D}} \hat{\mathbf{R}}_k' \hat{\mathbf{D}} \hat{\mathbf{D}}^{-1} \hat{\mathbf{R}}_0^{-1} \hat{\mathbf{D}}^{-1} \hat{\mathbf{D}} \hat{\mathbf{R}}_k \hat{\mathbf{D}} \hat{\mathbf{D}}) \end{aligned}$$

$$= T^2 \sum_{k=1}^s \frac{1}{T-k} \text{tr}(\hat{\mathbf{C}}_k' \hat{\mathbf{C}}_0^{-1} \hat{\mathbf{C}}_k \hat{\mathbf{C}}_0^{-1}). \quad (2.19)$$

Dengan $\hat{\mathbf{C}}_k$ menunjukkan matriks residual *cross-covariance* pada lag k yang dinyatakan dalam persamaan berikut:

$$\hat{\mathbf{C}}_k = \frac{1}{T-p} \sum_{t=p+k+1}^T \hat{\mathbf{a}}_t \hat{\mathbf{a}}_{t-k}', \quad (2.20)$$

sedangkan $\hat{\mathbf{C}}_0$ adalah matriks residual *cross-covariance* yang dinyatakan dalam persamaan berikut:

$$\hat{\mathbf{C}}_0 = \hat{\Sigma}_a, \quad (2.21)$$

dan $\hat{\mathbf{D}}$ menunjukkan matrik diagonal yang elemen diagonalnya adalah *standard errors* dari residual model *time series* yang dirumuskan seperti berikut:

$$\hat{\mathbf{D}} = \sqrt{\text{diag}(\hat{\mathbf{C}}_0)}. \quad (2.22)$$

Maka didapatkan persamaan dari matriks korelasi silang pada lag k dari residual adalah sebagai berikut:

$$\hat{\mathbf{R}}_k = \hat{\mathbf{D}}^{-1} \hat{\mathbf{C}}_k \hat{\mathbf{D}}^{-1}. \quad (2.23)$$

Jika $\dot{\mathbf{Y}}_t$ pada persamaan (2.3) adalah stationer dengan \mathbf{a}_t yang merupakan residual bersifat *white noise* dengan *mean* bernilai nol dan matriks kovarian bernilai positif, serta estimasi parameter pada persamaan (2.13) telah terestimasi secara konsisten, maka $Q_{m(s)}$ berdistribusi *chi-square* dengan derajat bebas $(s-p)m^2$.

Pengujian normal multivariat digunakan uji *Shapiro-wilks*. Misalkan $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_T$ merupakan variabel random yang bersifat independen dan identik dalam \mathbf{R}^p , dengan $p \geq 1$. Dengan $\mathbf{N}_p(\boldsymbol{\mu}, \Sigma)$ berdistribusi normal dengan $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_m)^T$ adalah vektor *mean* dan Σ matriks kovarian dari *series* $Y_{1,t}; Y_{2,t}; \dots; Y_{m,t}$. Jika $\mathbf{0}$ merupakan vektor nol dengan orde p dan \mathbf{I} merupakan matriks identitas berukuran $p \times p$, maka

karakteristik distribusi multivariat normal adalah $\mathbf{Y} \sim \mathbf{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ jika dan hanya jika $\mathbf{Z} = \boldsymbol{\Sigma}^{-1/2}(\mathbf{Y} - \boldsymbol{\mu}) \sim \mathbf{N}_p(\mathbf{0}, \mathbf{I})$.

Hipotesis yang digunakan untuk pengujian normal multivariat *Shapiro-wilks* adalah sebagai berikut:

H_0 : $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_T$ adalah sampel yang berasal dari $\mathbf{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$

H_1 : $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_T$ adalah sampel yang tidak berasal dari $\mathbf{N}_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.

Untuk menguji hipotesis nol dengan $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ tidak diketahui (Alva dan Estrada, 2009) digunakan

Statistik uji *Shapiro-wilks* adalah:

$$W^* = \frac{1}{p} \sum_{i=1}^p W_{Zi}, \quad (2.24)$$

dengan W_{Zi} adalah evaluasi statistik dari *Shapiro-Wilks* dihitung dari observasi ke- i yang ditransformasikan menjadi normal standar $Z_{i1}, Z_{i2}, \dots, Z_{iT}$, $i = 1, 2, \dots, p$. Pengujian normalitas dikatakan tolak H_0 ketika $W^* < c_{\alpha, T, p}$ pada taraf signifikan α .

2.4 GSTAR (*Generalized Space Time Auto regressive*)

Model GSTAR merupakan generalisasi dari model *Space Time Autoregressive* (STAR) yang juga merupakan spesifikasi dari model *Vector Autoregressive* (VAR). Perbedaan model GSTAR dan model STAR terletak pada pengasumsian parameternya. Model STAR mengasumsikan lokasi-lokasi yang digunakan dalam penelitian sama, sehingga model ini hanya dapat diterapkan pada lokasi yang bersifat seragam. Sedangkan pada model GSTAR terdapat asumsi yang menyatakan lokasi-lokasi penelitian yang bersifat heterogen, sehingga perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot.

Apabila diketahui suatu deret $\{\mathbf{Y}(t): t = 0, \pm 1, \pm 2, \dots\}$, merupakan sebuah deret waktu *multivariate* dari T pengamatan, maka persamaan model GSTAR untuk orde waktu $\text{AR}(p)$ dan orde spasial 1 dengan menggunakan 3 lokasi yang berbeda adalah sebagai berikut:

$$Y(t) = \Phi_{10}Y(t-1) + \Phi_{11}W^{(l)}Y(t-1) + a(t) \quad (2.25)$$

dengan

$Y(t)$ = vektor random berukuran $(T \times 1)$ pada waktu t

Φ_{10} = matriks koefisien parameter waktu

Φ_{11} = matriks koefisien parameter spasial

$W^{(l)}$ = nilai matriks pembobot ukuran $(m \times m)$ pada *lag* spasial ke- l .


Nilai pembobot yang dipilih harus memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{i \neq j}^{(l)} w_{ij}^{(l)} = 1$. $a(t)$ adalah vektor *error* yang memenuhi asumsi identik, independen, dan berdistribusi normal multivariat dengan rata-rata nol dan matriks varians-kovarians $\sigma^2 I_m$. Bentuk matriks untuk persamaan (2.25) dapat ditulis sebagai berikut:

$$\begin{aligned} \begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} &= \begin{bmatrix} \Phi_{10} & 0 & 0 \\ 0 & \Phi_{20} & 0 \\ 0 & 0 & \Phi_{30} \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} \\ &\quad + \begin{bmatrix} \Phi_{11} & 0 & 0 \\ 0 & \Phi_{21} & 0 \\ 0 & 0 & \Phi_{31} \end{bmatrix} \\ &\quad \begin{bmatrix} 0 & W_{12} & W_{13} \\ W_{21} & 0 & W_{23} \\ W_{31} & W_{32} & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}. \end{aligned} \quad (2.26)$$

Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde 1 karena orde yang lebih tinggi akan sulit untuk diinterpretasikan (Suhartono & Wutsqa, 2010). Sedangkan orde waktu dapat ditentukan dengan menggunakan AIC (Wei, 2006). Akan tetapi penentuan orde model berdasarkan nilai AIC tidak dapat menangkap pola *seasonal*, oleh karena itu penentuan orde model juga dapat dilakukan berdasarkan *plot* MCCF dan MPCCF yang terbentuk (Suhartono & Wutsqa, 2010).

2.4.1 Pemilihan Bobot Lokasi pada Model GSTAR

Pemilihan pembobotan lokasi adalah salah satu permasalahan utama yang sering dihadapi pada penerapan pemodelan GSTAR. Misalkan diketahui tiga buah lokasi dengan posisi seperti pada Gambar 2.3, maka beberapa metode yang dapat digunakan untuk menentukan bobot dari peta lokasi di atas antara lain adalah bobot seragam, invers jarak, dan normalisasi korelasi silang.



Gambar 2.3 Contoh Peta Lokasi

Metode yang digunakan sebagai pembobot lokasi dalam GSTAR adalah sebagai berikut.

1. Bobot lokasi seragam

Bobot lokasi seragam mengasumsikan bahwa lokasi-lokasi yang digunakan dalam penelitian bersifat homogen. Penentuan nilai bobot pada pembobotan ini adalah:

$$W_{ij} = \frac{1}{n_i}, \quad (2.27)$$

dengan n_i merupakan banyaknya lokasi yang berdekatan dan W_{ij} merupakan bobot lokasi ke- i dan ke- j .

2. Bobot lokasi invers jarak

Pembobotan dengan metode lokasi invers jarak dilakukan berdasarkan jarak sebenarnya antar lokasi dilapangan. Perhitungan bobot dengan metode ini diperoleh dari hasil invers jarak sebenarnya yang kemudian dinormalisasi. Berdasarkan Gambar 2.3 dapat dimisalkan perhitungan sebagai berikut:

$$\begin{aligned}
W_{AB}^* &= \frac{1}{d_{AB}} = \frac{1}{3}, \\
W_{AC}^* &= \frac{1}{d_{AC}} = \frac{1}{1} = 1, \\
W_{AB} &= \frac{W_{AB}^*}{W_{AB}^* + W_{AC}^*} = \frac{1/3}{1/3 + 1} = \frac{1}{4}, \\
W_{AC} &= \frac{W_{AC}^*}{W_{AC}^* + W_{AB}^*} = \frac{1}{1 + 1/3} = \frac{3}{4}.
\end{aligned}$$

Begitu juga dengan perhitungan bobot untuk lokasi-lokasi lainnya, sehingga matriks pembobot yang diperoleh dengan metode invers jarak adalah:

$$W_{ij} = \begin{bmatrix} 0 & 1/4 & 3/4 \\ 2/5 & 0 & 3/5 \\ 2/3 & 1/3 & 0 \end{bmatrix}.$$

3. Bobot lokasi normalisasi korelasi silang

Pembobotan lokasi normalisasi korelasi silang menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian (Suhartono & Atok, 2006). Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada lag waktu ke-*k*, $\text{corr}[Z_i(t), Z_j(t - k)]$, didefinisikan sebagai berikut:

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.28)$$

dengan $\gamma_{ij}(k)$ merupakan kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j*. Taksiran dari korelasi silang ini pada sampel dapat dihitung dengan persamaan berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^T (Y_i(t) - \bar{Y}_i)(Y_j(t - k) - \bar{Y}_j)}{\sqrt{\sum_{t=1}^T (Y_i(t) - \bar{Y}_i)^2 \sum_{t=1}^T (Y_j(t) - \bar{Y}_j)^2}}. \quad (2.29)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besaran-besaran korelasi silang antar lokasi pada waktu

yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR(1₁), yaitu sebagai berikut:

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq i} |r_{ik}(1)|} \text{ dengan } i \neq j. \quad (2.30)$$

2.4.2 Estimasi Parameter Model GSTAR

Estimasi parameter dilakukan dengan menggunakan metode *Generalized least square*. Dengan parameter regresi waktu Φ_{10} dan spasial Φ_{11} sama seperti pada persamaan (2.25) dimana $W^{(1)}$ menyatakan bobot lokasi yang satu terhadap lokasi lainnya, maka model GSTAR(1₁) dapat dinyatakan dalam matriks sebagai berikut:

$$Y(t) = XY(t-1) + a(t), \quad (2.31)$$

dengan $X = \Phi_0 + \Phi_1 W$ dimana Φ_0 dan Φ_1 merupakan matriks diagonal atas parameter autoregresi untuk waktu dan lokasi, dan W merupakan matriks bobot. Metode kuadrat terkecil sering digunakan dalam melakukan penaksiran parameter terhadap suatu model linier. Metode ini juga diterapkan pada model GSTAR(1₁) yang dapat ditulis dalam bentuk linier sebagai berikut:

$$Y = X\beta + A. \quad (2.32)$$

Dengan melakukan modifikasi terhadap bentuk matriks dari model GSTAR(1₁). Sehingga model persamaan untuk lokasi ke- i dapat ditulis sebagai $Y_i = X_i\beta_i + a_i$. Pada metode *Generalized least square* β dapat diperoleh dengan meminimalkan persamaan berikut (Tsay, 2014):

$$\begin{aligned} S(\beta) &= [vec(A)]' (\sum_a \otimes I_{T-p})^{-1} vec(A), \\ &= [vec(Y - X\beta)]' (\sum_a^{-1} \otimes I_{T-p}) vec(Y - X\beta), \\ &= tr[(Y - X\beta) \sum_a^{-1} (Y - X\beta)']. \end{aligned} \quad (2.33)$$

Hasil minimal pada persamaan (2.33) didapatkan persamaan estimasi β sebagai berikut:

$$\hat{\beta} = (X'X)^{-1}(X'Y) = \left[\sum_{t=p+1}^T x_t x_t' \right]^{-1} \sum_{t=p+1}^T x_t y_t'. \quad (2.34)$$

2.5 Peramalan Model *Multivariate Time Series*

Model yang didapatkan kemudian digunakan untuk peramalan. Peramalan berikut ini digunakan dengan mengasumsikan model telah diketahui dan mengabaikan sementara jika parameter telah dilakukan estimasi, dimisalkan h merupakan *forecast origin*, $l > 0$ merupakan *forecast horizon*. F_h menyatakan informasi yang tersedia pada waktu h (*inclusive*). Minimum MSE diramalkan dari y_{h+l} . Persamaan dengan prediksi 1 tahap kedepan dapat dituliskan dalam persamaan berikut (Tsay, 2014):

$$Y_h(1) = E(Y_{h+1}|F_h) = \Phi_0 + \sum_{t=1}^p \Phi_t Y_{h+1-t}, \quad (2.35)$$

persamaan untuk secara umum yaitu peramalan dengan l tahap kedepan dapat dituliskan dengan persamaan sebagai berikut:

$$Y_h(l) = E(Y_{h+l}|F_h) = \Phi_0 + \sum_{t=1}^p \Phi_t Y_{h+(l-t)}. \quad (2.36)$$

dan error dari peramalan ini dinyatakan sebagai berikut:

$$e_h(1) = a_{h+1} \quad (2.37)$$

Matriks kovarians dari nilai error peramalan ini adalah Σ . Jika Y_t memiliki stasioneritas yang lemah, maka peramalan sebanyak l tahap ke depan atau $Y_h(l)$ akan konvergen menuju vektor rata-rata μ sebagai peningkatan peramalan pada waktu l .

2.6 SVR (*Support Vector Regression*)


SVR merupakan suatu model dan pengembangan dari SVM untuk pemodelan regresi dan *time series*. SVM adalah suatu system pembelajaran dengan menggunakan ruang hipotesis

berupa fungsi-fungsi linier dalam sebuah ruang fitur (*feature space*) berdimensi tinggi. Konsep SVM menggunakan konsep ε – *insensitive loss function* yang dapat digeneralisasi untuk melakukan pendekatan fungsi yang dikenal dengan SVR (Gunn,1998). Konsep SVM menggunakan *hyperplane* tunggal pada ruang berdimensi banyak yang pada akhirnya partisi-partisi tersebut dapat diselesaikan secara non linier.

Konsep dasar dari *Support Vector Machine* sebenarnya merupakan penggabungan dari teori-teori komputasi yang telah ada seperti *hyperplane*, kernel, dan konsep-konsep pendukung lain. Konsep ini diperkenalkan oleh Boser, Vapnik, dan Guyon pada tahun 1992. *Support Vector Machine* adalah suatu teknik baru untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi, yang sangat populer belakangan ini. SVM berada dalam satu kelas dengan *Neural Network* dalam hal fungsi dan kondisi permasalahan yang bisa diselesaikan, keduanya masuk pada kelas *supervised learning* . Para ilmuwan telah banyak melakukan penelitian dengan menerapkan teknik SVM untuk menyelesaikan berbagai masalah nyata dalam kehidupan. Baik dalam bidang financial, cuaca, hingga kedokteran terbukti dalam banyak implementasi SVM member hasil yang lebih baik dari NN terutama dalam hal solusi yang yang dicapai (Santosa, 2007).

SVM secara teoritis dikembangkan untuk masalah klasifikasi dengan dua kelas sebagai usaha mencari *hyperplane* terbaik. *Hyperplane* merupakan fungsi pemisah antara dua kelas pada *input space*. Pada Gambar 2.4 diperlihatkan beberapa data yang merupakan anggota dua kelas, yaitu kelas untuk laki-laki dan perempuan. Kelas laki-laki dinotasikan dengan +1 dan kelas perempuan dinotasikan dengan -1. Data yang termasuk dalam kelas perempuan disimbolkan dengan lingkaran. Proses pembelajaran problem klasifikasi diterjemahkan untuk menemukan garis *hyperplane* yang memisahkan antara dua kelas tersebut. Pada Gambar 2.4 (a) terlihat alternatif garis pemisah (*discrimination boundaries*), sedangkan pada Gambar 2.4 (b) ditunjukkan bahwa terdapat garis *hyperplane* yang tepat berada

diantara dua kelas. Prinsip dasar dari analisis ini adalah menemukan *hyperplane* terbaik dengan meminimalkan kesalahan klasifikasi dan memaksimalkan margin geometriknya seperti pada Gambar 2.4 (b) (Prasetyo, 2014).




Gambar 2.4 Batas Keputusan untuk Set Data

Proses klasifikasi pada SVM menggunakan sebuah fungsi atau *hyperplane* untuk memisahkan dua kelas. SVM berusaha mencari *hyperplane* yang optimal dimana dua buah kelas pola dapat dipisahkan dengan maksimal (Nugroho, 2008). Dalam SVM bobot (w) dan bias (b) merupakan solusi global optimum dari *quadratic programming* yang merupakan formulasi matematika dari SVM sehingga cukup dengan sekali *running* akan menghasilkan solusi yang akan selalu sama untuk pilihan kernel dan parameter yang sama (Nurhayati dkk, 2015). Terdapat dua jenis data yang dapat diklasifikasikan dengan menggunakan SVM, yang pertama adalah *linearly separable data* yaitu data yang tidak dapat dipisahkan secara linier dan *nonlinearly separable data* yaitu data yang tidak dapat dipisahkan secara linier. SVM sendiri sebenarnya pertama kali diperkenalkan oleh Vapnik hanya dapat mengklasifikasikan data kedalam dua kelas. Akan tetapi dengan diadakannya pengembangan lebih lanjut, maka saat ini SVM telah dapat digunakan untuk mengklasifikasikan data lebih dari dua kelas. Terdapat dua cara

untuk mengimplementasikan *multi class* SVM ini yaitu dengan metode *one-against-all* dan *one-against-one*.

Konsep SVR didasarkan pada *structural risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*, sehingga SVR mampu mengatasi *overfitting*. Tujuan dari SVR adalah untuk mendapatkan suatu fungsi dengan tingkat kesalahan paling kecil sehingga menghasilkan suatu prediksi yang bagus. Ide dasar dari SVR yaitu dengan menentukan set data yang dibagi menjadi set training dan set testing. Kemudian dari set training tersebut ditentukan suatu fungsi regresi dengan batasan deviasi tertentu sehingga dapat menghasilkan prediksi yang mendekati dari target aktual.



Gambar 2.5 Batas Error dalam SVR

Pada Gambar 2.5 (a) menunjukkan bagaimana *error* pada SVR dihitung. Sampai dengan garis batas *error* ϵ , nilai *error* dianggap sama dengan 0, sedangkan di luar batas tersebut nilai *error* akan dihitung sebagai ξ atau ξ^* . Solusi pada masalah ini adalah dari sebuah garis, akan dibentuk sebuah tabung yang

memiliki toleransi terhadap *error* seperti yang ditunjukkan pada Gambar 2.5 (b). Fungsi regresi dari metode SVR akan sempurna apabila batas deviasinya sama dengan 0 sehingga dapat dituliskan sebagai berikut:

$$f(x) = w^T \varphi(x) + b, \quad (2.38)$$

dengan :

w = *vector* pembobot

$\varphi(x)$ = fungsi yang memetakan x dalam suatu dimensi

b = bias.

Simbol $\varphi(x)$ menunjukkan suatu titik di dalam *feature space* F yang merupakan hasil pemetaan x di dalam *input space*. Koefisien w dan b di sini berfungsi untuk meminimalkan fungsi resiko. Dengan meminimalkan fungsi resiko tersebut akan membuat suatu fungsi menjadi setipis mungkin, sehingga kapasitas fungsi dapat terkontrol, hal ini dinamakan regularisasi. Koefisien w dan b diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan sebagai berikut:

$$R(f(x)) = \frac{C}{T} \sum_{i=1}^T L_{\varepsilon}(y_i, f(x_i)) + \frac{1}{2} \|w\|^2, \quad (2.39)$$

dimana

$$L_{\varepsilon}(y_i, f(x_i)) = \begin{cases} 0 & ; |y_i - f(x_i)| \leq \varepsilon, \\ |y_i - f(x_i)| - \varepsilon & ; \text{lainnya.} \end{cases} \quad (2.40)$$

dengan L_{ε} merupakan ε - *insensitive loss function* , y_i adalah vektor dari nilai sebenarnya, C dan ε merupakan *hyper-parameter* yang sudah ditentukan.

Fungsi f diasumsikan dapat mengaproksimasi semua titik (x_i, y_i) dengan presisi ε , jika semua titik berada dalam rentang $f \pm \varepsilon$ atau disebut *feasible*. Sedangkan *infeasible* merupakan kondisi dimana ada beberapa titik yang berada diluar rentang $f \pm \varepsilon$. Titik-titik yang *infeasible* bisa ditambahkan variabel *slack* ξ, ξ^* untuk mengatasi *infeasible constrain*. Sehingga optimasi

pada persamaan (2.39) dapat ditransformasi kedalam bentuk berikut:

$$\min \frac{1}{2} \|w\|^2 + C \frac{1}{T} \sum_{i=1}^T (\xi_i + \xi_i^*), \quad (2.41)$$

dengan batasan $w\varphi(x_i) + b - y_i \leq \varepsilon + \xi_i^*$; $y_i - w\varphi(x_i) - b \leq \varepsilon + \xi_i$ dan $\xi, \xi^* \geq 0, i=1,2,\dots,n$.

Optimalisasi pada batasan tersebut bisa diselesaikan menggunakan *primal lagrangian* dalam bentuk sebagai berikut (Hong, 2008):

$$\begin{aligned} L(w, b, \xi, \xi^*, \alpha_i, \alpha_i^*, \beta_i, \beta_i^*) \\ = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^T (\xi_i + \xi_i^*) \right) \\ - \sum_{i=1}^T \beta_i [w\varphi(x_i) + b - y_i + \varepsilon + \xi_i^*] \\ - \sum_{i=1}^T \beta_i^* [y_i - w\varphi(x_i) - b + \varepsilon + \xi_i^*] \\ - \sum_{i=1}^T (\alpha_i \xi_i + \alpha_i^* \xi_i^*) \end{aligned} \quad (2.42)$$

persamaan (2.42) diminimalkan pada variabel primal w, b, ξ, ξ^* dan dimaksimalkan dalam bentuk *lagrangian multiplier* nonnegative $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*$ seperti ditampilkan pada persamaan berikut (Hong, 2008):

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^T (\beta_i - \beta_i^*) \varphi(x_i) = 0, \quad (2.43)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^T (\beta_i^* - \beta_i) = 0, \quad (2.44)$$

$$\frac{\partial L}{\partial \xi} = C - \beta_i - \alpha_i = 0, \quad (2.45)$$

$$\frac{\partial L}{\partial \xi^*} = C - \beta_i^* - \alpha_i^* = 0. \quad (2.46)$$

Sehingga kondisi Karush-Kuhn-Tucker terapkan untuk model regresi dan dengan menggunakan persamaan (2.41) didapatkan *dual lagrangian* pada persamaan (2.48) dengan mensubstitusikan persamaan (2.43), (2.44), (2.45), dan (2.46). Persamaan *dual lagrangian* didapatkan ketika fungsi kernel $K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$. Salah satu fungsi kernel yang paling sering digunakan adalah *Gaussian radial basis function* (RBF) seperti pada persamaan (2.47) (Haerdle, Prastyo, dan Hafner, 2014):

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \quad (2.47)$$

$$\begin{aligned} \partial(\beta_i, \beta_i^*) &= \sum_{i=1}^T y_i(\beta_i - \beta_i^*) \\ &\quad - \varepsilon \sum_{i=1}^T (\beta_i + \beta_i^*) - \frac{1}{2} \sum_{i=1}^T \sum_{j=1}^T (\beta_i \\ &\quad - \beta_i^*)(\beta_j - \beta_j^*) K(x_i, x_j). \end{aligned} \quad (2.48)$$

Dengan batasan,

$$\sum_{i=1}^T (\beta_i - \beta_i^*) = 0$$

$$0 \leq \beta_i \leq C, i = 1, 2, \dots, T,$$

$$0 \leq \beta_i^* \leq C, i = 1, 2, \dots, T.$$

Lagrange Multipliers pada persamaan (2.48) memenuhi persamaan $\beta_i * \beta_i^* = 0$. *Lagrange Multipliers* β_i dan β_i^*

dihitung dan vektor bobot optimal yang diharapkan dari *hyperplane* regresi adalah sebagai berikut:

$$w^* = \sum_{i=1}^T (\beta_i - \beta_i^*) \varphi(x), \quad (2.49)$$

sehingga didapatkan fungsi regresi

$$f(x, \beta_i, \beta_i^*) = \sum_{i=1}^l (\beta_i - \beta_i^*) K(x_i, x_j) + b. \quad (2.50)$$

2.7 Pemilihan Model Terbaik

Pemilihan model terbaik menggunakan kriteria nilai RMSE *in-sample* dan *out-sample* dengan membandingkan nilai *multivariate Root Mean Square Error* (RMSE) terkecil pada model. RMSE *in-sample* dari suatu model dapat diperoleh melalui perhitungan sebagai berikut (Wei, 2006):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{T} \sum_{i=1}^T (Y_i - \hat{Y}_i)^2}, \quad (2.51)$$

dimana T merupakan banyaknya data *in-sample*, Y_i menyatakan data *in-sample* ke- i , dan \hat{Y}_i merupakan data hasil ramalan ke- i . Sedangkan untuk data *out-sample* nilai RMSE dirumuskan seperti berikut (Wei, 2006):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{T_o} \sum_{j=1}^{T_o} (Y_j - \hat{Y}_j)^2}. \quad (2.52)$$

Dengan T_o merupakan banyaknya ramalan yang dilakukan, Y_j menyatakan data *out-sample* ke- j , dan \hat{Y}_j merupakan data hasil ramalan ke- j . Pemilihan model terbaik juga menggunakan nilai AIC, dengan persamaan sebagai berikut:

$$AIC = T \ln|\Sigma_p| + 2pm^2, \quad (2.53)$$

dimana p adalah banyak parameter, dan m adalah banyaknya *series*.

2.8 Curah Hujan

Curah Hujan merupakan jumlah air hujan yang turun pada suatu daerah dalam kurun waktu tertentu. Satuan yang diunakan dalam mengukur curah hujan adalah milimeter(mm). Curah hujan satu millimeter artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu milimeter atau sebanyak satu liter.

Variabilitas iklim tahunan dan antar-tahunan di Indonesia cukup unik karena tidak sama untuk semua daerah dan berpengaruh pada pola cuaca dan curah hujannya ,ijelaskan bahwa pola monsunial, ITCZ (*Inter Tropical Convergence Zone*) dan konveksi troposfer (MJO) ialah beberapa pola cuaca yang kerap mewarnai dinamika daerah beriklim tropis khususnya Indonesia. Selain itu dengan interaksi daratan dan lautan serta topografi wilayah dalam skala lokal maka kajian iklim regional di berbagai daerah di Indonesia merupakan suatu proses awal untuk memahami pengaruh dari pola-pola cuaca tersebut baik secara kualitatif maupun kuantitatif.

Berbagai parameter cuaca yang diawali oleh radiasi matahari diteruskan dengan fluktuasi suhu sehingga mengakibatkan perbedaan tekanan diberbagai ttiga menjadi pemicu pergerakan massa udara yang mengandung uap air dari siklus hidrologi, untuk kemudian mengalami proses-proses termodinamik sehingga dapat menjadi awan dan selanjutnya turun ke permukaan bumi sebagai hujan. Secara statistik curah hujan di wilayah beriklim tropis seperti Indonesia merupakan salah satu parameter yang dapat menggambarkan kondisi cuaca secara umum baik jangka pendek maupun jangka panjang.

Pola umum curah hujan di Indonesia dipengaruhi oleh letak geografis Indonesia. Pola umum hujan di Indonesia secara rinci diuraikan sebagai berikut:

1. Pantai sebelah barat setiap pulau memperoleh jumlah hujan yang lebih banyak daripada pantai sebelah timur.
2. Curah hujan di Indonesia bagian barat lebih besar daripada Indonesia bagian timur.
3. Banyaknya curah hujan di suatu daerah berbanding lurus dengan ketinggian posisi daerah tersebut. Curah hujan terbanyak umumnya berada pada ketinggian antara 600-900 m di atas permukaan laut.
4. Di daerah pedalaman, di semua pulau, musim hujan jatuh pada musim pancaroba. Begitu pula di daerah-daerah rawa yang besar.
5. Bulan maksimum hujan sesuai dengan letak DKAT.
6. Saat mulai turun, hujan bergeser dari daerah barat ke timur sehingga perolehan hujan terbanyak di daerah-daerah Indonesia tidak terjadi bersamaan.
7. Di Sulawesi Selatan bagian timur, Sulawesi Tenggara, Maluku Tengah, musim hujannya terjadi pada bulan Mei hingga Juni, dimana pada saat itu sedang berlangsung musim kemarau di daerah lain.

Rata-rata curah hujan di Indonesia tergolong cukup banyak, yaitu berkisar antara 2000-3000 mm/tahun. Akan tetapi rata-rata curah hujan antara tempat yang satu dengan yang lainnya adalah berbeda (www.belajar.kemdiknas.go.id).

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang didapatkan dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Jakarta Pusat. Data yang digunakan adalah data curah hujan di stasiun pengamatan Perak I, Perak II, dan Juanda dengan interval *series* selama 34 tahun, 10 bulan, dan 10 hari. Bentuk data merupakan data dasarian yang didapatkan dari akumulasi data harian curah hujan di setiap stasiun wilayah Surabaya. Kemudian data curah hujan ini akan dibagi menjadi data *in-sample* dan data *out-sample*, data *in-sample* meliputi bulan Januari 1981 sampai Desember 2013, sedangkan data *out-sample* meliputi bulan Januari 2014 hingga Dasarian pertama bulan November 2015. Bentuk struktur data ditampilkan pada Tabel 3.1.

Tabel 3.1 Struktur Data

Tahun	Bulan	Perak I	Perak II	Juanda
1981	1	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$
	2	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$
	3	$Y_{1,3}$	$Y_{2,3}$	$Y_{3,3}$
...
2013

	1188	$Y_{1,1188}$	$Y_{2,1188}$	$Y_{3,1188}$

3.2 Metode Analisis

Metode yang digunakan untuk penelitian ini yaitu metode VAR-SVR dan GSTAR-SVR, dengan langkah-langkah analisis sebagai berikut.

1. Mengakumulasikan data curah hujan harian kedalam bentuk data curah hujan dasarian.


2. Melakukan analisis statistika deskriptif dengan identifikasi *box plot* pada data dasarian curah hujan di tiga stasiun wilayah Surabaya.
3. Menentukan data *in-sample* dan data *out-sample*, dimana data *in-sample* adalah data curah hujan pada bulan Januari tahun 1981 sampai dengan bulan Desember tahun 2013, sedangkan untuk data *out-sampel* merupakan data curah hujan pada bulan Januari tahun 2014 sampai dengan bulan November dasarian pertama tahun 2015.
4. Mengidentifikasi pola pada masing-masing stasiun pengamatan yang bertujuan untuk mengetahui apakah curah hujan di Surabaya pada setiap wilayah memiliki pola yang sama di setiap tahunnya, selain itu juga digunakan untuk mengetahui adanya trend pada data. Identifikasi ini menggunakan *boxplot* dan plot *time series*.
5. Melakukan pemodelan VAR dengan langkah-langkah sebagai berikut:
 - a. Identifikasi orde model VAR dari data curah hujan di tiga lokasi stasiun wilayah Surabaya menggunakan MPCCF.
 - b. Melakukan estimasi parameter dari model VAR yang didapatkan.
 - c. Pemeriksaan diagnostik model apakah residual memenuhi asumsi *white noise*.
 - d. Pemilihan model terbaik berdasarkan nilai RMSE dan AIC
 - e. Melakukan peramalan curah hujan di tiga lokasi stasiun di Surabaya menggunakan model terbaik yang telah didapatkan.
6. Melakukan pemodelan GSTAR orde spasial (1) dengan pembobot lokasi:
 1. Bobot lokasi seragam
 2. Bobot lokasi invers jarak
 3. Bobot normalisasi korelasi silang

Langkah-langkah pemodelan GSTAR adalah sebagai berikut:

- a. Memilih pembobot lokasi.
 - b. Melakukan estimasi parameter dari model GSTAR.
 - c. Pemeriksaan diagnostic, apakah residual memenuhi asumsi *white noise*.
 - d. Pemilihan model terbaik berdasarkan nilai RMSE dan AIC
 - e. Melakukan peramalan curah hujan di tiga lokasi stasiun di Surabaya menggunakan model terbaik yang telah didapatkan
7. Melakukan pemodelan VAR-SVR dengan menjadikan variabel lag yang signifikan dari model VAR sebagai input pada model SVR dan menentukan parameter terbaik menggunakan algoritma *grid search*, pemodelan VAR-SVR dilakukan dengan langkah-langkah sebagai berikut:
- a. Menentukan nilai parameter kernel *gaussian*, parameter *cost*, parameter ϵ , dan sigma dengan menggunakan metode *grid-search*.
 - b. Evaluasi pemilihan model regresi pada data *training* dan *testing* menggunakan nilai RMSE.
8. Melakukan pemodelan GSTAR-SVR dengan menjadikan variabel lag yang signifikan dari model GSTAR sebagai input pada model SVR dan menentukan parameter terbaik menggunakan algoritma *grid-search*. Pemodelan GSTAR-SVR dilakukan dengan langkah-langkah sebagai berikut:
- a. Menentukan nilai parameter kernel *gaussian*, parameter *cost*, parameter ϵ , dan sigma dengan menggunakan metode *grid-search*.
 - b. Evaluasi pemilihan model regresi pada data *training* dan *testing* menggunakan nilai RMSE.
9. Membandingkan nilai RMSE pada masing-masing model pada data *in sample* dan *out sample*.

10. Melakukan peramalan curah hujan menggunakan model terbaik dari pemodelan VAR, GSTAR, VAR-SVR, dan GSTAR-SVR.

3.3 Diagram Alir



Gambar 3.1 Diagram Alir Penelitian

BAB IV

HASIL ANALISIS DAN PEMBAHASAN

Pada bagian ini akan dibahas mengenai hasil analisis penelitian curah hujan yang dilakukan pada tiga lokasi stasiun pengamatan di Surabaya, yaitu Perak 1, Perak 2, dan Juanda.

4.1 Statistika Deskriptif

Data yang digunakan pada penelitian tugas akhir ini adalah akumulasi data curah hujan harian menjadi data curah hujan sepuluh harian (dasarian) seperti yang ditampilkan pada Lampiran 1. untuk setiap lokasi stasiun pengamatan. Analisis statistika deskriptif akumulasi curah hujan dasarian dari ketiga lokasi secara umum ditampilkan pada Tabel 4.1.

Tabel 4.1 Statistika Deskriptif Data Curah Hujan Dasarian

Lokasi	Mean	StDev	Vars	Maks	Skewness	Kurtosis
Perak 1	45,64	56,62	3206,28	455	1,83	4,63
Perak 2	43,08	52,16	2720,95	263	1,5	2,07
Juanda	58,93	69,58	4841,92	408,4	1,45	2,29

Pada Tabel 4.1 terlihat bahwa nilai rata-rata data curah hujan dasarian tertinggi terjadi di Juanda yaitu sebesar 58,93 mm dengan nilai maksimum akumulasi dasarian sebesar 408,4 mm. Sedangkan untuk rata-rata akumulasi curah hujan dasarian terendah terjadi di Perak 2 yaitu sebesar 43,08 mm dengan nilai maksimum sebesar 263 mm. Analisis ini menunjukkan bahwa ketinggian curah hujan tertinggi di Surabaya terjadi di sekitar wilayah Juanda.

Ukuran keragaman data curah hujan bisa dilihat dari nilai varians dan standar deviasi. Sama halnya pada nilai rata-rata tertinggi yang terjadi di Juanda, untuk keragaman data tertinggi juga terjadi di stasiun pengamatan Juanda. Nilai standar deviasi dan varians masing-masing sebesar 69,58 dan 4841,92. Ukuran persebaran data tersebut menunjukkan bahwa persebaran data curah hujan di Juanda cenderung

tinggi. Stasiun pengamatan lainnya juga menunjukkan hal yang sama nilai standar deviasi dan varians untuk Perak 1 dan Perak 2 memiliki keragaman akumulasi curah hujan yang tinggi.

Persebaran data juga dapat dilihat dari nilai *skewness* dan kurtosis. Secara keseluruhan nilai *skewness* pada setiap lokasi bernilai lebih dari nol atau positif. Nilai *skewness* positif menunjukkan tingkat kemiringan grafik persebaran data yang melenceng kekanan atau dapat dikatakan sebagian besar nilai akumulasi curah hujan lebih kecil dari pada nilai rata-rata akumulasi curah hujan pada lokasi tersebut. sehingga dapat dinyatakan grafik persebaran data akumulasi curah hujan cenderung tidak mengikuti distribusi normal.

Nilai kurtosis menunjukkan nilai keruncingan grafik persebaran data. Pada Tabel 4.1 terlihat Perak 1 memiliki nilai kurtosis tertinggi yakni sebesar 4,63. Nilai kurtosis Perak 1 yang positif menunjukkan bahwa grafik persebaran data lebih runcing/lancip dibandingkan grafik persebaran data yang mengikuti distribusi normal, sehingga dapat dinyatakan persebaran data akumulasi curah hujan pada Perak 1 cenderung lebih homogen. Kasus ini disebut dengan jenis keruncingan leptokurtik. Sedangkan untuk dua lokasi stasiun pengamatan yang lain cenderung menunjukkan nilai yang hampir sama. Nilai kurtosis Perak 2 dan Juanda masing-masing sebesar 2,07 dan 2,29. Nilai kurtosis yang juga positif menunjukkan bahwa jenis keruncingan grafik persebaran data adalah leptokurtik, yang artinya tingkat keruncingan grafik persebaran data lebih runcing/lancip dari pada grafik data yang mengikuti persebaran distribusi normal. Sehingga dapat dinyatakan bahwa data akumulasi curah hujan di Juanda dengan nilai kurtosis mendekati 0 lebih mengikuti sebaran distribusi normal.

Analisis statistika deskriptif untuk ketiga stasiun pengamatan yaitu Perak 1, Perak 2, dan Juanda secara lebih detail juga dijelaskan beserta grafik *boxplot* untuk setiap stasiun.

4.1.1 Statistika Deskriptif Data Curah Hujan di Perak 1

Rata-rata akumulasi curah hujan pada Perak 1 secara keseluruhan sebesar 45,64. Persebaran dan keragaman data yang

cenderung tinggi terlihat dari nilai varians dan standar deviasi masing-masing sebesar 3206,28 dan 56,62. Persebaran data yang cenderung homogen terlihat dari nilai kurtosis yang bernilai positif. Nilai *skewness* yang menunjukkan grafik pesebaran data melenceng kearah kanan mengartikan data tidak berdistribusi normal. Secara lebih rinci berikut dijelaskan ukuran pemusatan dan persebaran data untuk setiap bulannya.

Tabel 4.2 Statistika Deskriptif Data Curah Hujan dasarian di Perak 1

Bulan	Dasarian	Mean	StDev	Varians	Min	Maks	Skew	Kurtosis
Januari	1	112.5	69.5	4831.9	10.9	323.1	0.98	1.37
	2	89.6	78.1	6100.3	6	455	3.4	15.08
	3	127.9	69.7	4862.2	27	309	0.95	1
Februari	1	112.9	65.6	4300	18.2	253.5	0.65	-0.68
	2	70.31	45.61	2080.18	11.8	223.4	1.57	2.95
	3	76.1	59.5	3544.8	5.7	224	1.07	0.36
Maret	1	108.6	62.4	3892.9	12.6	286.8	0.95	1.08
	2	83.9	59.3	3516.5	10.3	212.2	0.84	-0.17
	3	73.3	58	3362.6	16.3	261.5	1.62	2.74
April	1	65.56	42.46	1803.12	3.9	165.7	0.73	-0.09
	2	49.19	43.82	1920.1	0	213	2.04	5.2
	3	38.41	35.96	1293.19	0	139	1.42	1.65
Mei	1	31.36	27.14	736.64	0	135.1	1.94	5.64
	2	27.64	30.22	913.22	0	130	1.62	3.22
	3	21.64	31.98	1022.88	0	126.1	1.7	2.4
Juni	1	24.86	24.71	610.46	0	92	0.98	0.12
	2	21.43	31.4	985.69	0	109	1.7	2.06
	3	18.57	29.1	846.59	0	106.7	1.58	1.66

Tabel 4.2 Statistika Deskriptif Data Curah Hujan dasarian di Perak 1
(lanjutan)

Bulan	Dasarian	Mean	StDev	Varsians	Min	Maks	Skew	Kurtosis
Juli	1	7.56	16.12	259.99	0	71	2.71	7.5
	2	11.2	27.57	760.25	0	150.7	4.38	21.58
	3	7.39	21.34	455.55	0	114	4.4	20.81
Agustus	1	6.03	14.2	201.62	0	69.3	3.45	13.05
	2	3.72	13.72	188.16	0	75.6	4.89	25.35
	3	2.56	5.9	34.84	0	22.49	2.7	6.64
September	1	4.27	15.43	238.06	0	72.9	3.96	15.21
	2	5.22	20.39	415.79	0	107.3	4.54	21.34
	3	6.83	22.52	507.24	0	122.7	4.64	23.32
Oktober	1	10.9	21.94	481.5	0	87	2.67	6.42
	2	18.82	36.22	1312.23	0	167	2.7	8.29
	3	22.87	27.74	769.46	0	128.3	2	5.38
November	1	29.75	41.33	1707.93	0	150	1.74	2.42
	2	39.44	31.59	998	0	91.3	0.27	-1.34
	3	53.17	42.15	1776.73	0	152.5	0.87	-0.26
Desember	1	82.64	44.79	2006.49	0	205	0.64	1.2
	2	94	76.2	5807.1	3.5	267	0.93	-0.09
	3	82.86	45.12	2035.72	21.5	172.2	0.26	-1.22

Rata-rata akumulasi data curah hujan terlihat mulai menurun sejak bulan Mei hingga Oktober dengan nilai minimum akumulasi curah hujan dasarian sebesar 0 yang menunjukkan tidak terjadi hujan atau terjadi hujan namun sangat kecil hingga tidak dapat terdeteksi oleh alat dan nilai maksimum akumulasi curah hujan sebesar 150,7 mm yang terjadi pada bulan Juni. Hal ini dikarenakan bulan-bulan tersebut merupakan bulan terjadinya musim kemarau. Untuk bulan selain bulan tersebut menunjukkan nilai rata-rata yang lebih tinggi dengan nilai akumulasi data curah hujan maksimal adalah sebesar 455 mm yang terjadi pada dasarian kedua pada bulan Januari.


Keadaan persebaran data dapat dilihat dari nilai *skewness*, secara keseluruhan nilai *skewness* pada setiap bulan bernilai positif, untuk bulan-bulan terjadinya musim kemarau seperti bulan Mei hingga bulan Oktober cenderung memiliki nilai *skewness* yang lebih tinggi di bandingkan bulan terjadinya musim hujan yaitu bulan November hingga April. Dapat dikatakan bahwa data akumulasi curah hujan pada musim kemarau sebagian besar data curah hujan bernilai lebih kecil dari pada nilai rata-rata data curah hujan. Sehingga grafik persebaran data curah hujan cenderung melenceng kekanan.

Nilai kurtosis yang terdapat pada bulan di musim kemarau semua bernilai positif, semakin tinggi nilai kurtosis menunjukkan bahwa grafik persebaran data curah hujan semakin runcing yang berarti data cenderung homogen. Nilai kurtosis tertinggi terjadi pada bulan Agustus pada dasarian kedua dengan nilai kurtosis sebesar 25,35. Sebagian besar bulan terjadinya musim kemarau memiliki nilai kurtosis yang tinggi, yang menunjukkan persebaran data curah hujan pada bulan tersebut homogen yakni bernilai 0. Berbeda dengan bulan terjadinya musim hujan, sebagian besar memiliki nilai kurtosis yang lebih kecil hal ini menunjukkan persebaran data lebih beragam dan cenderung tidak homogen. Nilai kurtosis paling tinggi untuk bulan pada musim hujan terjadi pada bulan Januari dengan nilai kurtosis sebesar 15,08, hal ini menunjukkan sebaran data homogen namun dengan nilai curah hujan yang tinggi.

Tingkat persebaran data curah hujan juga bisa dilihat dari nilai varians dan standar deviasi. Nilai varians yang tinggi menunjukkan nilai keragaman yang tinggi pula. Nilai varians dan standar deviasi saling berbanding lurus kedua nilai menjelaskan keragaman dan kehomogenan data. Terlihat pada Tabel 4.2 nilai varians dan standar deviasi pada bulan terjadinya musim kemarau cenderung lebih kecil dari pada bulan terjadinya musim hujan, sehingga dapat dikatakan bahwa data curah hujan pada musim hujan lebih beragam dan tidak homogen dibandingkan dengan bulan terjadinya musim kemarau

yang cenderung tidak beragam dan homogeny, hal ini juga dikarenakan pada musim kemarau tercatat curah hujan yang 0.

Pola musim di Perak 1 dari musim hujan ke musim kemarau atau sebaliknya. Adapun pola peralihan dari musim hujan ke musim kemarau ataupun sebaliknya secara lebih jelas dapat dilihat pada visualisasi *boxplot* pada Gambar 4.1.



Gambar 4.1 Box Plot Akumulasi Data Curah Hujan Perdasarian di Perak 1.

Rata-rata nilai akumulasi data curah hujan dasarian di Perak 1 adalah sebesar 45,6. Nilai rata-rata ini digunakan sebagai pembanding nilai rata-rata perdasarian untuk melihat dasarian mana yang termasuk lebih kecil dari rata-rata curah hujan secara keseluruhan di Perak 1, dan mana yang lebih besar dari rata-rata tersebut. Gambar 4.1 menunjukkan bahwa pada bulan April pada dasarian ketiga terlihat bahwa nilai rata-rata pada dasarian tersebut kurang dari 45,6 ini menunjukkan bahwa pada dasarian tersebut terjadi masa peralihan dari musim hujan ke musim kemarau, bagitu juga pada bulan November pada dua dasarian pertama terlihat nilai rata-rata kurang dari 45,6 sehingga menunjukkan bahwa pada masa ini terjadi peralihan dari musim kemarau ke musim hujan. *Box plot* dengan warna kuning menunjukkan nilai rata-rata pada dasarian tersebut kurang dari nilai rata-rata secara keseluruhan di Perak 1, sedangkan *box plot* dengan warna biru muda menunjukkan nilai rata-rata yang

lebih dari rata-rata secara keseluruhan di Perak 1. Sebagian besar *box plot* dengan warna kuning menunjukkan dasarian pada bulan terjadinya musim kemarau dan *box plot* dengan warna biru muda menunjukkan dasarian pada bulan terjadinya musim hujan.

Analisis statistika deskriptif secara tahunan yang digunakan untuk mengetahui perkembangan curah hujan selama 33 tahun yaitu pada tahun 1981 sampai dengan 2013 dapat dilihat pada Tabel 4.3.

Tabel 4.3 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 1

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1981	48,62	46,67	2178,13	186,6	1,21	1,1
1982	43,5	74	5481,6	253,5	1,75	2
1983	45,89	51,43	2644,89	165,4	0,98	-0,2
1984	47,55	50,85	2585,36	213,5	1,39	1,91
1985	42,81	51,97	2701,19	196,5	1,59	2,17
1986	45,99	59,13	3496,1	240,9	1,83	3,12
1987	50,5	65,3	4265,8	223,4	1,36	0,86
1988	42,32	54,21	2938,39	186,1	1,44	1,22
1989	43,17	41,37	1711,2	165,9	1,09	0,76
1990	39,41	41,66	1735,21	121	0,62	-1,09
1991	40,8	62,8	3944,7	224	1,85	2,58
1992	51	64,6	4176,9	225	1,5	1,48
1993	36,75	47,21	2228,59	154	1,33	0,69
1994	31,17	44,99	2023,86	156	1,55	1,61
1995	48,01	50,18	2517,68	177,4	0,96	0,1

Tabel 4.3 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 1
(lanjutan)

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1996	39,97	49,88	2487,57	246	2,33	7,51
1997	38,88	39,72	1577,84	139	0,86	-0,1
1998	63,4	63,5	4034	267	1,52	2,33
1999	59,9	73,6	5412,6	323,1	1,97	4,58
2000	45,98	51,73	2676,39	177,5	1,22	0,49
2001	60,5	65	4224,6	262,2	1,33	1,71
2002	35,33	59,14	3497,33	305,3	3	11,88
2003	39,49	52,34	2739,18	198,6	1,52	1,89
2004	43	61,2	3742,1	286,8	2,29	6,39
2005	36,5	41,35	1710,08	156,4	1,25	1,03
2006	39,2	52,06	2709,95	171,4	1,24	0,5
2007	39,88	44,68	1996,48	156,3	1,04	0,08
2008	37,94	50,51	2551,12	237,9	2,07	5,79
2009	42,81	50,31	2530,69	152,7	0,83	-0,81
2010	65,89	56,56	3199,3	205	1,17	0,77
2011	48,42	56,48	3190,33	196,2	0,99	-0,13
2012	38,19	54,89	3012,58	205	1,66	2,1
2013	71,6	100,5	10100,2	455	2,26	5,63

Tahun dengan rata-rata total curah hujan tertinggi terjadi pada tahun 2013 dengan nilai sebesar 71,6 mm. Akumulasi curah hujan dasarian terbesar yang juga terjadi pada tahun 2013, yakni sebesar 455 mm.. Sedangkan tahun 1994 tercatat sebagai tahun kemarau panjang dengan rata-rata curah hujan terendah sebesar 31,17 dan nilai akumulasi curah hujan dasarian tertinggi pada tahun 1994 sebesar 156 mm.


Setiap tahunnya disepanjang periode tersebut terjadi perubahan nilai rata-rata curah hujan yang cukup fluktuatif. Analisis ukuran persebaran data curah hujan dapat dilihat dari nilai varians, standar

deviasi, *skewness*, dan kurtosis. Berdasarkan nilai varians dan standar deviasi tahun pada tahun 2013 curah hujan di Perak 1 memiliki keragaman data yang tertinggi dibandingkan dengan tahun-tahun yang lain, dengan nilai varians dan standar deviasi masing-masing sebesar 10100,2 dan 100,5. Angka ini juga menunjukkan bahwa data akumulasi curah hujan pada tahun 2013 sangat bervariasi dan tidak homogen. Sedangkan untuk data curah hujan yang cenderung tidak beragam dan homogen terjadi pada tahun 1997 dengan nilai varians dan standar deviasi sebesar 1577,84 dan 39,72.

Persebaran dan keragaman data yang juga dapat dilihat dari nilai *skewness* dan kurtosis. Nilai *skewness* yang menunjukkan kemiringan dari grafik persebaran data secara keseluruhan nilai *skewness* pada setiap tahun menunjukkan nilai yang positif dan cenderung mendekati nol hal ini menunjukkan bahwa grafik persebaran data sedikit melenceng kekanan yang berarti sebagian besar data akumulasi curah hujan dasarnya lebih kecil dari nilai rata-rata akumulasi curah hujan pada tahun tersebut. Namun nilai *skewness* pada setiap tahun secara keseluruhan cenderung mengikuti distribusi normal. Untuk nilai kurtosis sebagian besar menunjukkan nilai yang positif yang menunjukkan bahwa grafik persebaran data adalah leptokurtic hal ini dapat diartikan bahwa nilai kurtosis yang positif cenderung lebih memiliki data yang homogeny dengan keruncingan yang lebih tinggi dari pada grafik sebaran data berdistribusi normal. Berdasarkan nilai kurtosis tahun dengan kehomogenan data yang tertinggi terjadi pada tahun 2002 dengan nilai kurtosis sebesar 11,88. Sedangkan untuk nilai kurtosis yang negatif menunjukkan sebaran data yang mempunyai variasi tinggi dengan bentuk grafik sebaran data yang lebih landai dari pada grafik sebaran data yang mengikuti distribusi normal. Grafik sebaran data yang cenderung lebih landai terjadi pada tahun 1983, 1990, 1997, 2009, dan 2011. Tahun dengan distribusi sebaran data yang mendekati distribusi normal cenderung memiliki nilai kurtosis yang mendekati nol.

Keadaan curah hujan pada tahun yang memiliki nilai kurtosis hampir berdistribusi normal memiliki periode musim hujan dan

musim kemarau yang cenderung sama dari pada tahun yang memiliki sebaran data yang tidak mengikuti distribusi normal. Secara visual analisis statistika deskriptif untuk data curah hujan tahunan ditampilkan pada Gambar 4.2.



Gambar 4.2 *Box Plot* Data Curah Hujan Tahunan di Perak 1

Nilai rata-rata curah hujan secara keseluruhan adalah sebesar 45,6. *Box plot* dengan warna kuning menunjukkan nilai rata-rata data curah hujan yang memiliki nilai rata-rata kurang dari nilai rata-rata curah hujan secara keseluruhan. sedangkan warna biru muda menunjukkan nilai rata-rata yang lebih dari nilai rata-rata secara keseluruhan di Perak 1. Berdasarkan Gambar 4.2 terlihat bahwa nilai terendah terjadi pada tahun 1994 dan untuk tahun 2013 tercatat sebagai tahun dengan nilai rata-rata curah hujan tertinggi.

Tahun dengan nilai rata-rata data curah hujan lebih dari nilai rata-rata curah hujan secara keseluruhan pada Perak 1 cenderung memiliki musim hujan yang lebih panjang dari pada musim kemarau, dan sebaliknya untuk tahun yang memiliki nilai rata-rata curah hujan lebih rendah dari pada rata-rata curah hujan secara keseluruhan akan lebih panjang melewati musim kemarau dari pada musim hujan. Dilihat dari Gambar 4.2 tahun yang melewati musim kemarau panjang adalah tahun 1982, 1995, 1988, 1989, 1990, 1991, 1993, 1994, 1996, 1997, 2002 sampai tahun 2009, dan tahun 2012.

Sedangkan tahun selain tahun tersebut cenderung memiliki periode musim hujan yang lebih lama dari pada musim kemarau.

4.1.2 Statistika Deskriptif Data Curah Hujan di Perak 2

Nilai rata-rata akumulasi curah hujan pada Perak 2 secara keseluruhan sebesar 43,08. Persebaran data curah hujan terlihat dari nilai varians dan standar deviasi yang masing-masing sebesar 2720,95 dan 52,16. Ukuran persebaran data juga dapat dilihat dari nilai kurtosis dan nilai *skewness*. Nilai *skewness* positif menunjukkan grafik persebaran data melenceng kearah kanan mengartikan data tidak berdistribusi normal. Secara lebih detail berikut dijelaskan analisis statistika deskriptif data untuk setiap bulannya.

Tabel 4.4 Statistika Deskriptif Data Curah Hujan dasarian di Perak 2

Bulan	Dasarian	Mean	StDev	Varians	Min	Maks	Skew	Kurtosis
Januari	1	108.1	58.8	3461.4	22.7	263	0.65	0.1
	2	80.98	45.12	2036.18	15	192.5	0.5	-0.2
	3	109.2	58.4	3408	20.8	250.7	0.61	0.12
Februari	1	96.37	54.93	3017.27	21.5	222.1	0.84	0.08
	2	76.43	49.8	2480.17	14.9	242.2	1.53	3.05
	3	79.4	60.7	3683.9	2.8	221.5	0.73	-0.29
Maret	1	92.84	52.85	2792.76	1.8	215.9	0.41	-0.02
	2	85.01	57.17	3268.88	2	231	1.18	1.13
	3	66.8	53.74	2888.46	10.7	225.8	1.52	2.05
April	1	64.33	40.62	1650.28	8.6	165.7	0.67	0.21
	2	46.86	48.32	2334.52	0.7	258	2.86	10.92
	3	37.06	33.19	1101.71	0	114.1	1.1	0.36

Tabel 4.4 Statistika Deskriptif Data Curah Hujan dasarian di Perak 2
(lanjutan)

Bulan	Dasarian	Mean	StDev	Varsians	Min	Maks	Skew	Kurtosis
Mei	1	28.39	23.31	543.18	0	89.8	1.1	0.71
	2	30.18	31.49	991.72	0	114.1	1.21	0.87
	3	21.43	29.48	868.99	0	101.4	1.41	0.91
Juni	1	25.88	31.74	1007.15	0	151.2	2.36	7.06
	2	17.46	26.25	689.24	0	99	1.71	2.15
	3	19.44	29.21	852.95	0	93.5	1.51	1.21
Juli	1	7.19	14.86	220.79	0	70	2.88	9.61
	2	7.18	16.47	271.32	0	76.2	3.2	10.68
	3	7.08	19.99	399.53	0	105.8	4.17	19.45
Agustus	1	2.552	5.402	29.185	0	20.1	2.41	5.3
	2	1.5	5.663	32.071	0	29.8	4.49	21.11
	3	2.139	5.155	26.571	0	22.7	2.9	8.64
September	1	4.22	15.44	238.24	0	71.3	3.92	14.68
	2	4.24	15.53	241.18	0	86.9	5.04	27
	3	5.6	19.11	365.28	0	99.6	4.3	19.65
Oktober	1	8.1	15.8	249.64	0	55.5	2.16	3.79
	2	17.21	34.82	1212.11	0	144.5	2.55	6.2
	3	27.45	35.52	1261.51	0	166	2.11	6.13
November	1	27.08	32.63	1064.76	0	133.9	1.8	3.22
	2	31.59	27.91	778.98	0	90.5	0.56	-0.95
	3	51.34	37.84	1431.85	0	135.6	0.98	-0.06
Desember	1	84.59	50.67	2567.14	0.9	234.7	0.89	1.3
	2	88.5	73.1	5338.7	3.8	247.8	0.83	-0.4
	3	87.04	45.85	2102.56	11.4	172.6	0.2	-0.91

Nilai rata-rata akumulasi data curah hujan menunjukkan intensitas terjadinya hujan pada bulan tersebut. Terlihat bahwa rata-rata curah hujan mulai cenderung menurun sejak bulan Mei dan Juni

sampai dengan dasarian pertama pada bulan November dengan nilai minimum akumulasi curah hujan dasarian sebesar 0 yang menunjukkan tidak terjadi hujan atau terjadi hujan namun sangat kecil sehingga tidak dapat terdeteksi oleh alat dan nilai maksimum akumulasi curah hujan sebesar 151,2 mm yang terjadi pada dasarian pertama di bulan Juni. Hal ini dikarenakan bulan-bulan tersebut merupakan bulan terjadinya musim kemarau. Untuk bulan terjadinya musim hujan menunjukkan nilai rata-rata curah hujan yang lebih tinggi. Nilai akumulasi curah hujan maksimal adalah sebesar 258 mm yang terjadi pada dasarian kedua pada bulan April.


Grafik persebaran data dapat dilihat dari nilai *skewness*, secara keseluruhan nilai *skewness* pada setiap bulan bernilai positif, untuk bulan-bulan terjadinya musim kemarau seperti bulan Mei hingga bulan Oktober cenderung memiliki nilai *skewness* yang lebih tinggi di bandingkan bulan terjadinya musim hujan yaitu bulan November hingga April. Sehingga dapat dikatakan bahwa data akumulasi curah hujan pada musim kemarau sebagian besar memiliki akumulasi dasarian curah hujan yang lebih rendah dari pada nilai rata-rata akumulasi curah hujan tersebut. Sehingga grafik persebaran data curah hujan cenderung melenceng kekanan.

Nilai kurtosis juga dapat digunakan untuk melihat keragaman suatu data. Nilai kurtosis yang terdapat pada musim kemarau secara keseluruhan bernilai positif, semakin tinggi nilai kurtosis menunjukkan bahwa data cenderung homogen. Nilai kurtosis tertinggi terjadi pada bulan Agustus pada dasarian kedua dengan nilai kurtosis sebesar 21,11, keadaan ini sama halnya pada Perak 1. Sebagian besar bulan terjadinya musim kemarau memiliki nilai kurtosis yang tinggi, hal ini menunjukkan persebaran data curah hujan pada bulan tersebut homogen pada nilai akumulasi curah hujan sebesar 0 mm. Berbeda dengan bulan terjadinya musim hujan yang sebagian besar memiliki nilai kurtosis yang lebih kecil, nilai kurtosis yang kecil menunjukkan persebaran data lebih bervariasi dan cenderung tidak homogen. Nilai kurtosis paling tinggi pada bulan di musim hujan terjadi pada bulan April dasarian kedua dengan nilai

kurtosis sebesar 10,92, hal ini menunjukkan bahwa sebaran data lebih homogen pada nilai akumulasi curah hujan yang tinggi.

Ukuran persebaran data curah hujan juga dapat dilihat dari nilai varians dan standar deviasi. Nilai varians yang tinggi menunjukkan nilai keragaman yang tinggi pula. Nilai varians dan standar deviasi saling berbanding lurus, kedua nilai menjelaskan persebaran dan kehomogenan data. Terlihat pada Tabel 4.4 nilai varians dan standar deviasi pada bulan dimusim kemarau cenderung lebih kecil dari pada bulan terjadinya musim hujan, sehingga dapat dikatakan bahwa data curah hujan di musim hujan memiliki variasi yang tinggi dan cenderung tidak homogen dibandingkan dengan bulan di musim kemarau.

Pola musim di Indonesia memiliki beberapa fase yaitu pola musim dari musim hujan ke musim kemarau atau sebaliknya. Perubahan pola curah hujan di Perak 2 secara lebih jelas dapat dilihat pada visualisasi *boxplot* pada Gambar 4.3.



Gambar 4.3 *Box Plot* Akumulasi Data Curah Hujan Perdasarian di Perak 2.

Nilai rata-rata akumulasi data curah hujan dasarian di Perak 2 secara keseluruhan adalah sebesar 43,08. Nilai rata-rata ini digunakan sebagai pembanding nilai rata-rata perdasarian untuk melihat dasarian mana yang lebih kecil dari rata-rata curah hujan secara keseluruhan di Perak 2, dan mana yang lebih besar dari rata-rata tersebut. Bulan

April di dasarian ketiga nilai rata-rata pada dasarian tersebut kurang dari 43,08 ini menunjukkan bahwa pada dasarian tersebut terjadi masa peralihan dari musim hujan ke musim kemarau, begitu juga pada bulan November pada dua dasarian pertama terlihat nilai rata-rata kurang dari 43,08 sehingga menunjukkan terjadi peralihan dari musim kemarau ke musim hujan. *Box plot* dengan warna kuning menunjukkan dasarian terjadinya musim kemarau, *box plot* warna kuning banyak terjadi di bulan Mei sampai Oktober dan warna biru muda menunjukkan dasarian terjadinya musim hujan. Statistika deskriptif setiap tahun yang dapat digunakan untuk mengetahui perkembangan curah hujan selama 33 tahun dapat dilihat pada Tabel 4.5.

Tabel 4.5 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 2

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1981	52.7	54.17	2934.15	220.3	1.69	3.08
1982	40.2	67.4	4540	210.1	1.61	1.18
1983	47.74	52.77	2784.47	184.2	1.01	0.22
1984	42.21	43.46	1889.19	148.5	0.89	-0.37
1985	42.36	55.73	3105.67	221.6	1.8	2.97
1986	44.11	45.08	2032.53	170	1.17	0.73
1987	51	67.9	4605.9	250.7	1.68	2.27
1988	38.21	48.97	2398.07	181.4	1.49	1.71
1989	40.38	43.88	1925.25	167.9	1.22	0.73
1990	32.98	37.43	1400.98	122.4	0.93	-0.29
1991	37.88	55.88	3122.92	258	2.27	6.25
1992	45.23	52.14	2718.78	175.3	1.18	0.28

Tabel 4.5 Statistika Deskriptif Data Curah Hujan Tahunan di Perak 2
(lanjutan)

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1993	33.47	45.57	2077.01	162.7	1.73	2.4
1994	34.22	55.15	3041.41	225.8	1.88	3.38
1995	45.92	47.9	2294.09	165.7	0.82	-0.37
1996	41.68	50.69	2569.27	220	1.63	3.15
1997	32.26	37.27	1389.04	136.7	1.13	0.54
1998	55.53	53.67	2880.36	247.8	1.75	4.08
1999	54	60.8	3698.4	194.1	1	-0.14
2000	49.25	55.5	3079.7	175.7	1.16	0.12
2001	54.26	53.87	2901.78	228.3	1.15	1.81
2002	34.29	50.69	2569.09	241.3	2.42	7.36
2003	35.07	49.74	2474.4	222.1	2.07	4.89
2004	40.35	51.66	2669.06	215.9	1.67	2.84
2005	33.54	39.59	1567.11	139.8	1.27	0.82
2006	33.81	44.28	1960.47	120.9	0.87	-0.95
2007	42.01	47.94	2298.06	193.4	1.24	1.33
2008	36.59	47.54	2259.85	181.3	1.37	1.21
2009	40.77	52.77	2784.53	221.5	1.6	2.66
2010	60.71	56.02	3138.14	242.2	1.38	1.92
2011	49.8	60.7	3679.8	235.7	1.42	1.69
2012	39.16	51.79	2681.93	185.5	1.21	0.44
2013	59.9	68	4629.9	263	1.5	1.87


2010 merupakan tahun yang memiliki rata-rata curah hujan tertinggi di sepanjang periode dengan nilai rata-rata 60,71 mm. Meskipun demikian curah hujan dasarian tertinggi terjadi pada tahun 2013 dengan tingkat curah hujan sebesar 263 mm. Tahun 1997 tercatat sebagai tahun kemarau panjang dengan nilai rata-rata curah hujan sebesar 32,26 mm dengan nilai akumulasi curah hujan dasarian tertinggi pada tahun 1994 sebesar 136,7 mm.

Nilai rata-rata curah hujan disetiap tahun cukup fluktuatif. Begitu pula pada ukuran persebaran data curah hujan yang dapat dilihat dari nilai varians, standar deviasi, *skewness*, dan kurtosis. Berdasarkan nilai varians dan standar deviasi, tahun 2013 curah hujan di Perak 2 memiliki variasi tingkat curah hujan yang paling tinggi dibandingkan dengan tahun-tahun yang lain, nilai varians dan standar deviasi tahun 2013 masing-masing sebesar 4629,9 dan 68. Angka ini juga menunjukkan bahwa data akumulasi curah hujan pada tahun 2013 tidak homogen. Sedangkan untuk data curah hujan yang cenderung lebih homogen terjadi pada tahun 1997 dengan nilai varians dan standar deviasi sebesar 1389,04 dan 37,27.

Keragaman data yang juga dapat dilihat dari nilai *skewness* dan kurtosis. Nilai *skewness* yang menunjukkan kemiringan dari grafik persebaran data, secara keseluruhan nilai *skewness* pada setiap tahun menunjukkan nilai yang positif hal ini menunjukkan bahwa grafik persebaran data melenceng kekanan yang berarti sebagian besar data akumulasi curah hujan dasarnya lebih kecil dari nilai rata-rata akumulasi curah hujan pada tahun tersebut. Untuk nilai kurtosis sebagian besar bernilai positif yang menunjukkan bahwa grafik persebaran data adalah leptokurtik hal ini dapat diartikan bahwa nilai kurtosis yang positif cenderung lebih memiliki data yang homogen dengan keruncingan yang lebih tinggi dari pada grafik sebaran data yang mengikuti distribusi normal. Berdasarkan nilai kurtosis, tahun dengan grafik persebaran data berbentuk runcing terjadi pada tahun 2002 dengan nilai kurtosis sebesar 7,36. Sedangkan untuk nilai kurtosis yang negatif menunjukkan sebaran data yang mempunyai variasi tinggi dengan bentuk grafik sebaran data yang lebih landai dari pada grafik sebaran data yang mengikuti distribusi normal. Grafik sebaran data curah hujan yang cenderung lebih landai dari distribusi normal ini terjadi pada tahun 1984, 1990, 1995, 1999, dan 2006. Tahun dengan distribusi sebaran data yang mendekati distribusi normal cenderung memiliki nilai kurtosis yang mendekati nol.

Keadaan curah hujan pada tahun yang memiliki grafik sebaran data yang hampir berdistribusi normal memiliki periode musim hujan dan musim kemarau yang cenderung sama dari pada tahun yang

memiliki sebaran data yang tidak mengikuti distribusi normal. Secara visual analisis statistika deskriptif untuk data curah hujan tahunan ditampilkan pada Gambar 4.4.



Gambar 4.4 *Box Plot* Data Curah Hujan Tahunan di Perak 2

Nilai rata-rata curah hujan secara keseluruhan adalah sebesar 43,1. *Box plot* dengan warna kuning menunjukkan nilai rata-rata data curah hujan yang memiliki nilai rata-rata kurang dari nilai rata-rata curah hujan secara keseluruhan. sedangkan warna biru muda menunjukkan nilai rata-rata yang lebih dari nilai rata-rata secara keseluruhan di Perak 2. Berdasarkan Gambar 4.4 terlihat bahwa nilai terendah terjadi pada tahun 1997 dan untuk tahun 2013 tercatat sebagai tahun dengan nilai rata-rata curah hujan tertinggi.

Tahun dengan nilai rata-rata data curah hujan lebih dari nilai rata-rata curah hujan secara keseluruhan pada Perak 2 cenderung memiliki musim hujan yang lebih panjang dari pada musim kemarau, dan sebaliknya untuk tahun yang memiliki nilai rata-rata curah hujan lebih rendah dari pada rata-rata curah hujan secara keseluruhan akan lebih panjang melewati musim kemarau dari pada musim hujan. Dilihat dari Gambar 4.4 tahun yang melewati musim kemarau panjang adalah tahun 1982, 1984, 1985, 1988, 1989, 1990, 1991, 1993, 1994, 1996, 1997, 2002 sampai tahun 2009, dan tahun 2012.

Sedangkan tahun selain tahun tersebut cenderung memiliki periode musim hujan yang lebih lama dari pada musim kemarau.

4.1.3 Statistika Deskriptif Data Curah Hujan di Juanda

Rata-rata akumulasi curah hujan pada Perak 1 secara keseluruhan sebesar 58,93. Nilai ini merupakan nilai tertinggi dari pada lokasi-lokasi lain. Keragaman data yang cenderung tinggi terlihat dari nilai varians dan standar deviasi yang masing-masing sebesar 4841,92 dan 69,58. Persebaran data yang cenderung homogen terlihat dari nilai kurtosis positif. Nilai *skewness* yang menunjukkan grafik persebaran data terlihat lebih melenceng kearah kanan yang menunjukkan data cenderung tidak berdistribusi normal, karena sebagian besar data curah hujan lebih kecil dari rata-rata curah hujan di Juanda. Secara lebih rinci berikut dijelaskan ukuran pemusatan dan persebaran data untuk akumulasi curah hujan di Juanda setiap bulannya.

Tabel 4.6 Statistika Deskriptif Data Curah Hujan dasarian di Juanda

Bulan	Dasarian	Mean	StDev	Varians	Min	Maks	Skew	Kurtosis
Januari	1	163.5	88.4	7806.3	14.2	408.4	0.74	1.11
	2	107.88	56.82	3228.45	33.9	216.7	0.27	-1.34
	3	152.5	73.3	5379	10	327	0.42	0.08
Februari	1	138	82.4	6787.1	32.3	390.7	1.49	2.45
	2	124.6	80.2	6425.5	11.6	344.1	0.82	0.49
	3	115.9	77.5	6013.3	11	338.1	1.31	1.54
Maret	1	117.4	60.7	3679.5	40.3	324.4	1.88	4.2
	2	93.8	62.9	3954.9	15	249	0.95	0.23
	3	101.6	65.7	4314.6	2	213.4	0.27	-1.18

Tabel 4.6 Statistika Deskriptif Data Curah Hujan dasarian di Juanda
(lanjutan)

Bulan	Dasarian	Mean	StDev	Vars	Min	Maks	Skew	Kurtosis
April	1	88	59.8	3577.7	2.8	239.5	0.8	-0.08
	2	79.85	42.77	1829.41	11.2	155	-0.1	-0.93
	3	74.9	68.8	4733.6	7	271	1.61	2.32
Mei	1	73.1	60.3	3634	0	242.3	0.92	0.44
	2	51.88	45.1	2034.06	0	173	0.86	0.32
	3	50.4	68.2	4645.6	0	222.8	1.5	1.16
Juni	1	42.32	46.45	2157.49	0	171	1.01	0.21
	2	37.43	46.82	2192.1	0	188	1.6	2.34
	3	33.33	56.32	3171.73	0	204	1.97	3.22
Juli	1	16.64	22.4	501.67	0	93.6	1.58	2.91
	2	11.88	25.55	652.55	0	108.5	2.87	8.14
	3	9.81	25.02	625.98	0	105	3.15	9.72
Agustus	1	8.65	21.65	468.7	0	75.8	2.55	5.23
	2	0.37	1.771	3.135	0	10	5.38	29.73
	3	0.894	2.74	7.51	0	13.2	3.6	13.55
September	1	1.82	6.08	36.99	0	27.1	3.51	11.87
	2	2.47	11.83	139.91	0	66.8	5.38	29.73
	3	2.23	7.24	52.46	0	34.7	3.63	13.62
Oktober	1	5.91	19.62	384.77	0	104.2	4.38	20.87
	2	12.45	26.96	726.74	0	118.7	2.67	7.58
	3	22.95	37.07	1374.32	0	155.9	2.08	4.39
November	1	20.59	28.79	828.65	0	97.2	1.39	0.71
	2	32.08	35.76	1278.74	0	126	1.16	0.38
	3	60.82	41.73	1741.74	0	139	0.11	-1.1
Desember	1	78.44	51.65	2667.72	0	209.4	0.45	-0.3
	2	100.4	73	5335.2	8	332.4	1.37	2.38
	3	86.58	47.98	2302.32	11	185	0.42	-0.76


Sejak bulan Mei hingga Oktober nilai rata-rata akumulasi data curah hujan terlihat mulai menurun dengan nilai minimum akumulasi curah hujan dasarian sebesar 0 yang menunjukkan tidak terjadi hujan atau terjadi hujan namun sangat kecil hingga tidak dapat terdeteksi oleh alat. Hal ini dikarenakan bulan-bulan tersebut merupakan bulan terjadinya musim kemarau. Untuk bulan selain bulan tersebut menunjukkan nilai rata-rata yang lebih tinggi dengan nilai akumulasi data curah hujan maksimal adalah sebesar 408,4 mm yang terjadi pada dasarian pertama di bulan Januari.

Keadaan persebaran data dapat dilihat dari nilai *skewness* dan kurtosis, secara keseluruhan nilai *skewness* pada setiap bulan bernilai positif, untuk bulan-bulan terjadinya musim kemarau seperti bulan Mei hingga bulan Oktober cenderung memiliki nilai *skewness* yang lebih tinggi di bandingkan bulan terjadinya musim hujan yaitu bulan November hingga April. Dapat dikatakan bahwa data akumulasi curah hujan pada musim kemarau sebagian besar data curah hujan bernilai lebih kecil dari pada rata-rata data curah hujan pada dasarian tersebut. Sehingga grafik persebaran data curah hujan cenderung melenceng kekanan.

Nilai kurtosis yang terdapat pada bulan di musim kemarau semua bernilai positif, semakin tinggi nilai kurtosis menunjukkan bahwa grafik persebaran data curah hujan semakin runcing yang berarti data cenderung homogen. Nilai kurtosis tertinggi terjadi pada bulan Agustus pada dasarian kedua dengan nilai kurtosis sebesar 29,73. Sebagian besar bulan terjadinya musim kemarau memiliki nilai kurtosis yang tinggi, yang menunjukkan persebaran data curah hujan pada bulan tersebut homogen yakni bernilai 0. Berbeda dengan bulan terjadinya musim hujan, sebagian besar memiliki nilai kurtosis yang lebih kecil hal ini menunjukkan persebaran data lebih beragam dan cenderung tidak homogen. Nilai kurtosis paling tinggi untuk bulan pada musim hujan terjadi pada bulan Februari dasarian pertama dengan nilai kurtosis sebesar 2,45, hal ini menunjukkan sebaran data lebih homogen dibandingkan bulan musim hujan yang lain.

Tingkat keragaman data curah hujan bisa dilihat dari nilai varians dan standar deviasi. Nilai varians yang tinggi menunjukkan nilai keragaman yang tinggi pula. Nilai varians dan standar deviasi saling berbanding lurus, kedua nilai menjelaskan keragaman dan kehomogenan data. Terlihat pada Tabel 4.6 nilai varians dan standar deviasi pada bulan terjadinya musim kemarau cenderung lebih kecil dari pada bulan terjadinya musim hujan, sehingga dapat dikatakan bahwa data curah hujan pada musim hujan lebih beragam dan tidak homogen dibandingkan dengan bulan terjadinya musim kemarau yang cenderung tidak beragam dan homogen, hal ini juga dikarenakan pada musim kemarau tercatat curah hujan yang paling banyak bernilai 0 mm.

Pola musim di Juanda dari musim hujan ke musim kemarau atau sebaliknya. Adapun pola peralihan dari musim hujan ke musim kemarau dan sebaliknya secara lebih jelas dapat dilihat pada visualisasi *box plot* pada Gambar 4.5.



Gambar 4.5 Box Plot Akumulasi Data Curah Hujan Perdasarian di Juanda.

Rata-rata nilai akumulasi data curah hujan dasarian di Juanda adalah sebesar 58,9. Nilai rata-rata ini digunakan sebagai batas kriteria untuk melihat dasarian mana yang termasuk lebih kecil dari rata-rata curah hujan secara keseluruhan di Juanda, dan mana yang lebih besar dari rata-rata tersebut. Gambar 4.5 menunjukkan bahwa

mulai pada bulan Mei pada dua dasarian terakhir nilai rata-rata pada dasarian tersebut kurang dari 58,9, hal ini menunjukkan bahwa pada dasarian tersebut terjadi masa peralihan dari musim hujan ke musim kemarau, begitu juga pada bulan November pada dua dasarian pertama terlihat nilai rata-rata kurang dari 58,9 sehingga menunjukkan bahwa pada masa-masa ini terjadi peralihan dari musim kemarau ke musim hujan. *Box plot* dengan warna kuning menunjukkan nilai rata-rata pada dasarian tersebut kurang dari nilai rata-rata secara keseluruhan di Juanda, sedangkan *box plot* dengan warna biru muda menunjukkan nilai rata-rata yang lebih dari rata-rata secara keseluruhan di Juanda. Sebagian besar *box plot* dengan warna kuning menunjukkan dasarian pada bulan terjadinya musim kemarau dan *box plot* dengan warna biru muda menunjukkan dasarian pada bulan terjadinya musim hujan.

Analisis statistika deskriptif secara tahunan yang digunakan untuk mengetahui perkembangan curah hujan selama 33 tahun yaitu pada tahun 1981 sampai dengan 2013 dapat dilihat pada Tabel 4.7.

Tabel 4.7 Statistika Deskriptif Data Curah Hujan Tahunan di Juanda

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1981	76	82.1	6735.5	290.4	0.88	-0.28
1982	52.1	77.5	6013	344.5	1.9	4.44
1983	60	61.2	3744.2	192.6	0.53	-1.13
1984	63.9	73.9	5459.1	327	1.64	3.25
1985	55.75	58.63	3437	216.9	1.3	1.36
1986	57.8	67.2	4517	213.4	0.99	-0.13
1987	55.3	68.9	4752.3	243.9	1.29	1.14
1988	48.6	56.35	3175.42	222.1	1.4	1.72
1989	61.22	55.75	3108.45	222.8	1.09	1.04

Tabel 4.7 Statistika Deskriptif Data Curah Hujan Tahunan di Juanda
(lanjutan)

Tahun	Mean	StDev	Varians	Maks	Skew	Kurtosis
1990	45.6	59.45	3534.33	209.4	1.43	1.4
1991	54.8	89.7	8037.9	408.4	2.41	6.8
1992	73.4	80.4	6461.9	290.5	1.09	0.39
1993	55.14	59.71	3565.49	171	0.6	-1.22
1994	50.7	83.7	7001.7	366.2	2.08	4.73
1995	67.06	58.76	3452.85	188	0.37	-0.98
1996	64.14	58.48	3420.11	222.8	0.87	0.3
1997	33.71	51.51	2653.06	205.8	1.71	2.55
1998	96.2	75	5625.2	267	0.53	-0.67
1999	56.1	61.7	3807.6	197	0.93	-0.23
2000	60.4	63.7	4052.4	207.9	0.9	-0.17
2001	71.6	72.7	5288.6	324.4	1.46	2.85
2002	40.91	57.09	3259.42	213.3	1.66	2.36
2003	58.9	84	7053	344.1	1.85	3.34
2004	61.7	86.9	7543	338.1	1.73	2.56
2005	61	59.66	3559.36	242.3	1.02	0.87
2006	64.4	94.7	8962.2	390.7	1.87	3.48
2007	43.18	59.91	3589.68	240.5	1.97	4.04
2008	41.7	63.6	4045.9	332.4	3	12.02
2009	55.4	77.6	6016	271.3	1.45	1.16
2010	87.6	70.1	4916.6	285	1.11	1.24
2011	64.9	70.3	4937.7	271	1.19	1.29
2012	37.22	50.27	2527.42	185.3	1.55	1.81
2013	68	64.7	4180.6	249	0.69	0.07

Tahun dengan rata-rata total curah hujan tertinggi terjadi pada tahun 1996 dengan nilai sebesar 96,2 mm. Akumulasi curah hujan dasarian terbesar yang terjadi di Juanda sebesar 408,4 mm yang


terjadi pada tahun 1991. Sedangkan tahun 1997 tercatat sebagai tahun kemarau panjang dengan rata-rata curah hujan terendah sebesar 33,71 dan nilai akumulasi curah hujan dasarian tertinggi pada tahun 1997 sebesar 205,8 mm.

Setiap tahunnya disepanjang periode tersebut terjadi perubahan nilai rata-rata curah hujan yang cukup fluktuatif. Analisis ukuran persebaran data curah hujan dapat dilihat dari nilai varians, standar deviasi, *skewness*, dan kurtosis. Berdasarkan nilai varians dan standar deviasi tahun pada tahun 2013 curah hujan di Perak 1 memiliki keragaman data yang tertinggi dibandingkan dengan tahun-tahun yang lain, dengan nilai varians dan standar deviasi masing-masing sebesar 10100,2 dan 100,5. Angka ini juga menunjukkan bahwa data akumulasi curah hujan pada tahun 2013 sangat bervariasi dan tidak homogen. Sedangkan untuk data curah hujan yang cenderung tidak beragam dan homogen terjadi pada tahun 1997 dengan nilai varians dan standar deviasi sebesar 1577,84 dan 39,72.

Persebaran dan keragaman data yang juga dapat dilihat dari nilai *skewness* dan kurtosis. Nilai *skewness* yang menunjukkan kemiringan dari grafik persebaran data secara keseluruhan nilai *skewness* pada setiap tahun menunjukkan nilai yang positif hal ini menunjukkan bahwa grafik persebaran data sedikit melenceng kekanan yang berarti sebagian besar data akumulasi curah hujan dasarian lebih kecil dari nilai rata-rata akumulasi curah hujan pada tahun tersebut. Namun nilai *skewness* pada setiap tahun secara keseluruhan cenderung mengikuti distribusi normal. Untuk nilai kurtosis sebagian besar menunjukkan nilai yang positif yang menunjukkan bahwa grafik persebaran data adalah leptokurtik hal ini dapat diartikan bahwa nilai kurtosis yang positif cenderung lebih memiliki data yang homogen dengan keruncingan yang lebih tinggi dari pada grafik sebaran data berdistribusi normal. Sedangkan untuk nilai kurtosis yang negatif menunjukkan sebaran data yang mempunyai keragaman tinggi dengan bentuk grafik sebaran data yang lebih landai dari pada grafik sebaran data yang mengikuti distribusi normal. Data curah hujan yang bernilai negatif ini terjadi pada tahun 1981, 1983, 1986, 1993, 1995, 1998 sampai dengan 2000.

Tahun dengan distribusi sebaran data yang mendekati distribusi normal cenderung memiliki nilai kurtosis yang mendekati nol.

Curah hujan pada tahun yang memiliki nilai kurtosis hampir berdistribusi normal memiliki periode musim hujan dan musim kemarau yang cenderung sama dari pada tahun yang memiliki sebaran data yang tidak mengikuti distribusi normal. Visualisasi analisis statistika deskriptif untuk data curah hujan tahunan ditampilkan pada Gambar 4.6.



Gambar 4.6 Box Plot Data Curah Hujan Tahunan di Juanda

Nilai rata-rata curah hujan secara keseluruhan adalah sebesar 58,9. *Box plot* dengan warna kuning menunjukkan nilai rata-rata data curah hujan yang memiliki nilai rata-rata kurang dari nilai rata-rata curah hujan secara keseluruhan. sedangkan warna biru muda menunjukkan nilai rata-rata yang lebih dari nilai rata-rata secara keseluruhan di Juanda. Berdasarkan Gambar 4.6 terlihat bahwa nilai terendah terjadi pada tahun 1997 dan untuk tahun 2013 tercatat sebagai tahun dengan nilai rata-rata curah hujan tertinggi.

Tahun dengan nilai rata-rata data curah hujan lebih dari nilai rata-rata curah hujan secara keseluruhan pada Juanda cenderung memiliki musim hujan yang lebih panjang dari pada musim kemarau, dan sebaliknya untuk tahun yang memiliki nilai rata-rata curah hujan lebih rendah dari pada rata-rata curah hujan secara keseluruhan akan


lebih panjang melewati musim kemarau dari pada musim hujan. Dilihat dari Gambar 4.6 tahun yang melewati musim kemarau panjang adalah tahun 1982, 1985, 1986, 1987, 1988, 1990, 1991, 1993, 1994, 1997, 1999, 2002, 2007 sampai dengan 2009, dan tahun 2012. Sedangkan untuk tahun lainnya cenderung memiliki periode musim hujan yang lebih lama dari pada musim kemarau.

4.2 Pemodelan *Vector Autoregressive* (VAR)

Pemodelan *vector autoregressive* (VAR) pada penelitian ini menggunakan data *in sampel* sebagai data *training* dan data *out sampel* sebagai data *testing*. Data *in sample* yang digunakan adalah akumulasi data curah hujan dasarian dari bulan Januari 1981 sampai dengan bulan Desember 2013, dengan jumlah data sebanyak 1188. Sedangkan data *out sampel* menggunakan data curah hujan dasarian dari bulan Januari 2014 sampai dengan bulan November dasarian pertama pada tahun 2015, dengan jumlah data sebanyak 67.


4.2.1 Identifikasi Orde Model VAR


Identifikasi orde model VAR dilakukan setelah data sudah stasioner. Identifikasi stasioneritas data dilakukan pada ketiga lokasi stasiun pengamatan yaitu Perak 1, Perak 2, dan Juanda. Identifikasi stasioneritas data pada ketiga lokasi dilakukan secara visual menggunakan plot MCCF. Data dikatakan stasioner ketika terdapat sedikit tanda positif atau negative yang muncul. Apabila plot MCCF menunjukkan banyaknya tanda positif atau negatif yang muncul, maka data masih belum stasioner. Tanda positif menunjukkan nilai tersebut lebih besar dari 2 kali standar *error*, sedangkan tanda negatif menunjukkan bahwa nilai tersebut lebih kecil dari pada -2 kali standar *error*. Plot MCCF untuk ketiga lokasi terlihat pada Gambar 4.7.



Gambar 4.7 MCCF Plot Data Curah Hujan di Ketiga Lokasi


Tanda positif dan negatif banyak yang muncul secara bersamaan dalam plot MCCF pada Gambar 4.7 menunjukkan bahwa data curah hujan di ketiga lokasi tidak stasioner. Untuk mengatasi ketidakstasioneran ini maka perlu dilakukan *differencing*. Namun Gambar 4.7 juga diduga adanya pola musiman yang terlihat dari pola perubahan tanda positif dan negatif. Untuk mengetahui pola musiman terjadi dalam periode berapa dasarian, dapat diketahui dengan mengidentifikasi secara univariate. Identifikasi univariate dilakukan menggunakan plot ACF, yang ditampilkan pada Gambar 4.8.





Gambar 4.8 ACF Plot Data Curah Hujan di (a) Perak 1, (b) Perak 2, (c) Juanda


Pola musiman terlihat pada masing-masing lokasi pengamatan. Sebelum melakukan *differencing* terlihat bahwa setelah lag 1, lag-lag berikutnya cenderung terlihat *dies down* dan karena data terlihat musiman 36 yang artinya terjadi pola yang berulang setiap periode 1 tahun, yaitu di lag 36 dan kelipatannya, maka perlu dilakukan *differencing* 36, setelah dilakukan *differencing* plot MCCF dari data tersebut menunjukkan bahwa data sudah stasioner yang terlihat dari banyaknya tanda titik (.) yang muncul dalam plot MCCF pada Gambar 4.9.



Gambar 4.9 MCCF Plot Data Curah Hujan Setelah *Differencing* 36

Gambar 4.9 menunjukkan bahwa data sudah stasioner, maka selanjutnya dilakukan identifikasi orde model VAR. identifikasi orde model VAR dilakukan dengan menggunakan plot MPCCF dari data yang sudah stasioner. Plot MPCCF untuk data yang sudah stasioner di tampilkan pada Gambar 4.10.

Karena model yang ingin dibentuk dalam analisis ini adalah model VAR, maka identifikasi orde model lebih ditekankan melalui plot MPCCF. Berdasarkan plot MPCCF pada Gambar 4.10 terlihat bahwa nilai MPCCF dari data curah hujan di ketiga lokasi signifikan mulai dari lag pertama dan lag kedua. Ini mengindikasikan bahwa orde nonmusiman dari model VAR ini adalah dua.



Gambar 4.10 MPCCF Plot Data Curah Hujan yang Sudah Stasioner

Orde musiman dapat diketahui dari tanda yang muncul pada lag 36 dan kelipatannya. Berdasarkan Gambar 4.10 terlihat bahwa data signifikan pada lag ke-36. Namun ternyata tanda juga muncul atau signifikan pada lag ke-72, lag ke-108, lag ke-144 dan lag ke-180. Plot MPCCF dari lag 64 sampai dengan lag 200 dapat dilihat pada Lampiran 2. Sehingga diperoleh lima model dugaan, yaitu VARIMA

$(2,0,0)(1,1,0)^{36}$, VARIMA $(2,0,0)(2,1,0)^{36}$, VARIMA $(2,0,0)(3,1,0)^{36}$, VARIMA $(2,0,0)(4,1,0)^{36}$, dan VARIMA $(2,0,0)(5,1,0)^{36}$.

4.2.2 Estimasi Parameter Model VAR

Estimasi parameter model VAR dilakukan terhadap kelima model dugaan, yaitu VARIMA $(2,0,0)(1,1,0)^{36}$, VARIMA $(2,0,0)(2,1,0)^{36}$, VARIMA $(2,0,0)(3,1,0)^{36}$, VARIMA $(2,0,0)(4,1,0)^{36}$, dan VARIMA $(2,0,0)(5,1,0)^{36}$. Parameter-parameter pada setiap model yang telah diestimasi selanjutnya dilakukan uji signifikansi. Pengujian signifikansi parameter ini menggunakan hipotesis uji dimana hipotesis awal atau H_0 menyatakan parameter tidak signifikan, dan hipotesis alternatifnya atau H_1 menyatakan bahwa parameter signifikan. Penarikan kesimpulan dapat dilakukan dengan membandingkan nilai p -value dari hasil pengujian dengan nilai signifikansi (α) sebesar 5% atau 0,05. Jika diperoleh p -value lebih kecil dari α maka H_0 akan ditolak, sehingga kesimpulan yang diambil ialah parameter signifikan, dan begitu pula sebaliknya.

a. Estimasi Parameter untuk Model VARIMA $(2,0,0)(1,1,0)^{36}$

Model dengan orde nonmusiman 2 dan orde musiman 1 memiliki 27 parameter yang akan diuji signifikansinya. Berdasarkan hasil estimasi parameter tidak semua parameter signifikan berpengaruh terhadap model. Parameter yang tidak signifikan memiliki nilai p -value yang bernilai lebih dari 5%. Karena tidak semua parameter berpengaruh signifikan terhadap model, maka dilakukan *restrict* untuk parameter yang tidak signifikan. Perintah *restrict* dilakukan secara bertahap dimulai dari parameter yang memiliki nilai p -value yang tertinggi sampai semua parameter bernilai kurang dari α sebesar 5% atau signifikan terhadap model. Hasil estimasi parameter dari model VARIMA $(2,0,0)(1,1,0)^{36}$ selengkapnya ditampilkan pada Lampiran 3. Jika p -value dari masing-masing parameter sudah lebih kecil dari nilai α maka dapat dikatakan bahwa parameter-parameter tersebut sudah signifikan terhadap model. Berikut hasil estimasi parameter yang sudah signifikan terhadap model VARIMA $(2,0,0)(1,1,0)^{36}$ dapat dilihat pada Tabel 4.8.

Tabel 4.8 Hasil Estimasi Parameter Model VARIMA (2,0,0)(1,1,0)³⁶

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	ϕ_{112}	0,09151	0,0284	3,22	0,0013	y2(t-1)
	ϕ_{212}	0,05951	0,0183	3,25	0,0012	y2(t-2)
	ϕ_{213}	0,05161	0,0224	2,3	0,0214	y3(t-2)
	$\phi_{(36)11}$	-0,34019	0,0471	-7,22	0,0001	y1(t-36)
	$\phi_{(36)12}$	-0,13864	0,0499	-2,78	0,0056	y2(t-36)
Perak 2 y2(t)	ϕ_{122}	0,0829	0,0262	3,16	0,0016	y2(t-1)
	ϕ_{223}	0,06163	0,02	3,08	0,0021	y3(t-2)
	$\phi_{(36)21}$	0,20519	0,0436	4,71	0,0001	y1(t-36)
	$\phi_{(36)22}$	-0,6375	0,0461	-13,81	0,0001	y2(t-36)
Juanda y3(t)	ϕ_{132}	0,09494	0,03698	2,57	0,0104	y2(t-1)
	ϕ_{133}	0,06598	0,02593	2,54	0,0111	y3(t-1)
	ϕ_{233}	0,11986	0,02621	4,57	0,0001	y3(t-2)
	$\phi_{(36)31}$	0,16036	0,05731	2,8	0,0052	y1(t-36)
	$\phi_{(36)32}$	-0,13462	0,06021	-2,24	0,0255	y2(t-36)
	$\phi_{(36)33}$	-0,46089	0,02624	-17,57	0,0001	y3(t-36)

Diketahui dari 27 parameter yang terbentuk pada model VARIMA (2,0,0)(2,1,0)³⁶ tersisa 15 parameter yang signifikan setelah dilakukan *restrict* sebanyak 12 parameter. Hasil estimasi parameter model VARIMA (2,0,0)(1,1,0)³⁶ setelah dilakukan *restrict* ditampilkan dalam Tabel 4.8, yang menunjukkan bahwa terdapat 15 parameter yang memiliki pengaruh signifikan terhadap model. Untuk mempermudah penyusunan model, nilai-nilai koefisien parameter ini selanjutnya diubah ke dalam bentuk matriks. Matrik koefisien dari model VARIMA (2,0,0)(1,1,0)³⁶ adalah sebagai berikut:

$$\phi_1 = \begin{bmatrix} 0 & 0,09151 & 0 \\ 0 & 0,0829 & 0 \\ 0 & 0,0949 & 0,06598 \end{bmatrix}, \phi_2 = \begin{bmatrix} 0 & 0,05951 & 0,05161 \\ 0 & 0 & 0,06163 \\ 0 & 0 & 0,11986 \end{bmatrix},$$

$$\phi_{36} = \begin{bmatrix} -0,34019 & -0,13864 & 0 \\ 0,20519 & -0,6375 & 0 \\ 0,16036 & -0,13462 & -0,46089 \end{bmatrix}.$$

b. Estimasi Parameter untuk Model VARIMA (2,0,0)(2,1,0)³⁶

Model VARIMA (2,0,0)(2,1,0)³⁶ adalah model yang menggunakan orde nonmusiman dua dan orde musiman dua. Orde nonmusiman terbentuk dari lag 1 dan 2 yang signifikan. Untuk orde musiman terbentuk dari lag ke-36 dan lag ke-72 yang signifikan, Model ini mempunyai 36 parameter. Namun tidak semua parameter tersebut menghasilkan parameter yang signifikan terhadap model.

Parameter yang signifikan akan menghasilkan nilai *p-value* yang lebih kecil dari nilai α yang ditentukan oleh penulis sebesar 5% ($\alpha=0,05$). Untuk mencari parameter-parameter yang signifikan, dilakukan *restrict* pada parameter-parameter yang tidak signifikan. Perintah *restrict* dilakukan secara bertahap dimulai dari parameter dengan nilai *p-value* tertinggi sampai didapatkan parameter-parameter yang signifikan atau parameter dengan nilai *p-value* lebih kecil dari α . Hasil estimasi parameter yang sudah dilakukan *restrict* ditampilkan pada Tabel 4.9.

Total parameter yang dihasilkan dari model VARIMA (2,0,0)(2,1,0)³⁶ berkurang sebanyak 18 parameter setelah dilakukan *restrict*. 18 parameter pada model VARIMA (2,0,0)(2,1,0)³⁶ memiliki *p-value* lebih kecil dari ($\alpha=0,05$), sehingga dapat dikatakan parameter-parameter yang tersisa tersebut sudah signifikan dalam model.

Tabel 4.9 Hasil Estimasi Parameter Model VARIMA (2,0,0)(2,1,0)³⁶

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	ϕ_{111}	0,07956	0,02543	3,13	0,0018	y1(t-1)
	ϕ_{212}	0,04333	0,0181	2,39	0,0169	y2(t-2)
	ϕ_{213}	0,05203	0,02124	2,45	0,0145	y3(t-2)
	$\phi_{(36)11}$	-0,52987	0,04877	-10,86	0,0001	y1(t-36)
	$\phi_{(36)12}$	-0,11343	0,05148	-2,2	0,0278	y2(t-36)
	$\phi_{(72)11}$	-0,24985	0,04864	-5,14	0,0001	y1(t-72)
	$\phi_{(72)12}$	-0,13315	0,05219	-2,55	0,0109	y2(t-72)
Perak 2 y2(t)	ϕ_{121}	0,07458	0,02305	3,24	0,0012	y1(t-1)
	ϕ_{223}	0,05854	0,01859	3,15	0,0017	y3(t-2)
	$\phi_{(36)21}$	0,19643	0,0443	4,43	0,0001	y1(t-36)
	$\phi_{(36)22}$	-0,80891	0,04678	-17,29	0,0001	y2(t-36)
	$\phi_{(72)21}$	0,09924	0,04409	2,25	0,0246	y1(t-72)
	$\phi_{(72)22}$	-0,46811	0,04737	-9,88	0,0001	y2(t-72)
Juanda y3(t)	ϕ_{131}	0,11152	0,0301	3,7	0,0002	y1(t-1)
	ϕ_{233}	0,09658	0,02436	3,96	0,0001	y3(t-2)
	$\phi_{(36)33}$	-0,64607	0,02587	-24,97	0,0001	y3(t-36)
	$\phi_{(72)32}$	-0,07481	0,03437	-2,18	0,0298	y2(t-72)
	$\phi_{(72)33}$	-0,37093	0,02713	-13,67	0,0001	y3(t-72)

Parameter-parameter yang sudah signifikan ini dibentuk ke dalam matriks dan diperoleh matriks-matriks koefisien parameter dari model VARIMA (2,0,0)(2,1,0)³⁶ adalah sebagai berikut:

$$\phi_1 = \begin{bmatrix} 0,07956 & 0 & 0 \\ 0,07458 & 0 & 0 \\ 0,11152 & 0 & 0 \end{bmatrix}, \phi_2 = \begin{bmatrix} 0 & 0,04333 & 0,05203 \\ 0 & 0 & 0,05854 \\ 0 & 0 & 0,09658 \end{bmatrix},$$

$$\phi_{36} = \begin{bmatrix} -0,52987 & 0,11343 & 0 \\ 0,19643 & -0,80891 & 0 \\ 0 & 0 & -0,64607 \end{bmatrix},$$

$$\phi_{72} = \begin{bmatrix} -0,24985 & -0,13315 & 0 \\ 0,09924 & -0,46811 & 0 \\ 0 & -0,07481 & -0,37093 \end{bmatrix}.$$

c. Estimasi Parameter untuk Model VARIMA (2,0,0)(3,1,0)³⁶

Estimasi parameter menggunakan model VARIMA (2,0,0)(3,1,0)³⁶ menghasilkan parameter sebanyak 45 parameter. Parameter-parameter tersebut selanjutnya akan diuji signifikansi. Parameter yang tidak signifikan memiliki nilai *p-value* yang bernilai lebih dari α ($\alpha=0,05$). Karena tidak semua parameter berpengaruh signifikan terhadap model, maka dilakukan *restrict*. Perintah *restrict* dilakukan secara bertahap dimulai dari parameter yang memiliki nilai *p-value* yang tertinggi sampai semua parameter signifikan terhadap model dan bernilai kurang dari α . Jika *p-value* dari masing-masing parameter sudah lebih kecil dari nilai α maka dapat dikatakan bahwa parameter-parameter tersebut sudah signifikan terhadap model.

Parameter yang dihasilkan dari model VARIMA (2,0,0)(2,1,0)³⁶ sebanyak 45, setelah dilakukan *restrict* jumlah parameter berkurang sebanyak 23 parameter dan didapatkan 22 parameter yang signifikan terhadap model. 22 parameter ini memiliki *p-value* lebih kecil dari ($\alpha=0,05$). Untuk lebih jelasnya berikut hasil estimasi parameter yang sudah signifikan dari model VARIMA (2,0,0)(3,1,0)³⁶ dapat dilihat pada Tabel 4.10.

Tabel 4.10 Hasil Estimasi Parameter Model VARIMA (2,0,0)(3,1,0)³⁶

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 (y1)	ϕ_{112}	0.07457	0.02525	2.95	0.0032	y1(t-1)
	ϕ_{212}	0.04083	0.01779	2.29	0.0219	y2(t-2)

Tabel 4.10 Hasil Estimasi Parameter Model VARIMA (2,0,0)(3,1,0)³⁶
(lanjutan)

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	ϕ_{213}	0.06057	0.02115	2.86	0.0043	y3(t-2)
	$\phi_{(36)11}$	-0.68702	0.02895	-23.73	0.0001	y1(t-36)
	$\phi_{(72)11}$	-0.49797	0.03263	-15.26	0.0001	y1(t-72)
	$\phi_{(108)11}$	-0.33313	0.03113	-10.7	0.0001	y1(t-108)
	$\phi_{(108)11}$	0.13726	0.0379	3.62	0.0003	y2(t-108)
Perak 2 y2(t)	ϕ_{121}	0.06882	0.02295	3	0.0028	y1(t-1)
	ϕ_{223}	0.06105	0.01858	3.29	0.0011	y3(t-2)
	$\phi_{(36)21}$	0.14525	0.03477	4.18	0.0001	y1(t-36)
	$\phi_{(36)22}$	-0.83561	0.03118	-26.8	0.0001	y2(t-36)
	$\phi_{(72)21}$	0.07348	0.03714	1.98	0.0481	y1(t-72)
	$\phi_{(72)22}$	-0.60021	0.03511	-17.1	0.0001	y2(t-72)
	$\phi_{(108)22}$	-0.22823	0.02747	-8.31	0.0001	y2(t-108)
Juanda y3(t)	ϕ_{131}	0.08137	0.03247	2.51	0.0124	y1(t-1)
	ϕ_{133}	0.0677	0.02438	2.78	0.0056	y3(t-1)
	ϕ_{231}	-0.07003	0.03018	-2.32	0.0205	y1(t-2)
	ϕ_{233}	0.12627	0.02648	4.77	0.0001	y3(t-2)
	$\phi_{(36)33}$	-0.71347	0.02778	-25.68	0.0001	y3(t-36)
	$\phi_{(72)32}$	-0.07352	0.03367	-2.18	0.0292	y2(t-72)
	$\phi_{(72)33}$	-0.49706	0.03269	-15.2	0.0001	y3(t-72)
	$\phi_{(108)33}$	-0.20237	0.02763	-7.32	0.0001	y3(t-108)

Parameter yang tersisa adalah 22 parameter. Hasil estimasi parameter model VARIMA (2,0,0)(3,1,0)³⁶ yang sudah signifikan kemudian dituliskan matrik koefisien dari model VARIMA (2,0,0)(3,1,0)³⁶ sebagai berikut:

$$\phi_1 = \begin{bmatrix} 0,07457 & 0 & 0 \\ 0,06882 & 0 & 0 \\ 0,08137 & 0 & 0,0677 \end{bmatrix},$$

$$\phi_2 = \begin{bmatrix} 0 & 0,04083 & 0,06057 \\ 0 & 0 & 0,06105 \\ 0,08137 & 0 & 0,0677 \end{bmatrix},$$

$$\phi_{36} = \begin{bmatrix} -0,68702 & 0 & 0 \\ 0,14525 & -0,83561 & 0 \\ 0 & 0 & -0,71347 \end{bmatrix},$$

$$\phi_{72} = \begin{bmatrix} -0,49797 & 0 & 0 \\ 0,07348 & -0,60021 & 0 \\ 0 & -0,07352 & -0,49706 \end{bmatrix},$$

$$\phi_{108} = \begin{bmatrix} -0,33313 & 0,13726 & 0 \\ 0 & -0,22823 & 0 \\ 0 & 0 & -0,20237 \end{bmatrix}.$$

d. Estimasi Parameter untuk Model VARIMA (2,0,0)(4,1,0)³⁶

Model VARIMA dengan orde nonmusiman dua dan orde musiman empat menghasilkan 54 parameter, Berdasarkan hasil estimasi parameter tidak semua parameter berpengaruh signifikan terhadap model. Parameter yang tidak signifikan memiliki nilai *p-value* yang bernilai lebih dari 5%. Untuk itu perlu dilakukan *restrict* agar didapatkan parameter-parameter yang signifikan terhadap model. Perintah *restrict* dilakukan secara bertahap dimulai dari parameter yang memiliki nilai *p-value* yang tertinggi sampai semua parameter yang bernilai kurang dari α . Jika *p-value* dari masing-masing parameter memiliki nilai lebih kecil dari α maka dapat dikatakan bahwa parameter tersebut sudah signifikan terhadap model.

Parameter signifikan yang dihasilkan pada model VARIMA (2,0,0)(4,1,0)³⁶ lebih banyak dari model VARIMA sebelumnya. Berikut hasil estimasi parameter yang sudah signifikan dalam model VARIMA (2,0,0)(4,1,0)³⁶ dapat dilihat pada Tabel 4.11.

Tabel 4.11 Hasil Estimasi Parameter Model VARIMA (2,0,0)(4,1,0)³⁶

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	ϕ_{213}	0.06057	0.02115	2.86	0.0043	y3(t-2)
	$\phi_{(36)11}$	-0.68702	0.02895	-23.73	0.0001	y1(t-36)
	$\phi_{(72)11}$	-0.49797	0.03263	-15.26	0.0001	y1(t-72)
	$\phi_{(108)11}$	-0.33313	0.03113	-10.7	0.0001	y1(t-108)
	$\phi_{(108)11}$	0.13726	0.0379	3.62	0.0003	y2(t-108)
Perak 2 y2(t)	ϕ_{121}	0.06882	0.02295	3	0.0028	y1(t-1)
	ϕ_{223}	0.06105	0.01858	3.29	0.0011	y3(t-2)
	$\phi_{(36)21}$	0.14525	0.03477	4.18	0.0001	y1(t-36)
	$\phi_{(36)22}$	-0.83561	0.03118	-26.8	0.0001	y2(t-36)
	$\phi_{(72)21}$	0.07348	0.03714	1.98	0.0481	y1(t-72)
	$\phi_{(72)22}$	-0.60021	0.03511	-17.1	0.0001	y2(t-72)
	$\phi_{(108)22}$	-0.22823	0.02747	-8.31	0.0001	y2(t-108)
Juanda y3(t)	ϕ_{131}	0.08137	0.03247	2.51	0.0124	y1(t-1)
	ϕ_{133}	0.0677	0.02438	2.78	0.0056	y3(t-1)
	ϕ_{231}	-0.07003	0.03018	-2.32	0.0205	y1(t-2)
	ϕ_{233}	0.12627	0.02648	4.77	0.0001	y3(t-2)
	$\phi_{(36)33}$	-0.71347	0.02778	-25.68	0.0001	y3(t-36)
	$\phi_{(72)32}$	-0.07352	0.03367	-2.18	0.0292	y2(t-72)
	$\phi_{(72)33}$	-0.49706	0.03269	-15.2	0.0001	y3(t-72)
	$\phi_{(108)33}$	-0.20237	0.02763	-7.32	0.0001	y3(t-108)

Model VARIMA (2,0,0)(4,1,0)³⁶ memiliki 28 parameter yang signifikan setelah dilakukan restrict sebanyak 26 parameter. Untuk mempermudah penyusunan model, nilai-nilai koefisien parameter ini selanjutnya diubah ke dalam bentuk matriks. Matriks koefisien dari model VARIMA (2,0,0)(4,1,0)³⁶ adalah sebagai berikut:

$$\phi_1 = \begin{bmatrix} 0,08576 & 0 & 0 \\ 0,07537 & 0 & 0 \\ 0,0767 & 0 & 0,06785 \end{bmatrix},$$

$$\begin{aligned}\phi_2 &= \begin{bmatrix} -0,1242 & 0,15702 & 0,0564 \\ -0,10323 & 0,09673 & 0,0639 \\ -0,09053 & 0 & 0,11712 \end{bmatrix}, \\ \phi_{36} &= \begin{bmatrix} -0,73164 & 0 & 0 \\ 0,16898 & -0,8977 & 0 \\ 0 & 0 & -0,74691 \end{bmatrix}, \\ \phi_{72} &= \begin{bmatrix} -0,60705 & 0 & 0 \\ 0,07393 & -0,70884 & 0 \\ 0 & -0,07787 & -0,58127 \end{bmatrix}, \\ \phi_{108} &= \begin{bmatrix} -0,50632 & 0,14915 & 0 \\ 0 & -0,38961 & 0 \\ 0 & 0 & -0,32507 \end{bmatrix}, \\ \phi_{144} &= \begin{bmatrix} -0,21933 & 0 & 0 \\ 0 & -0,20648 & 0 \\ 0 & 0 & -0,16491 \end{bmatrix}.\end{aligned}$$

e. Estimasi Parameter untuk Model VARIMA (2,0,0)(5,1,0)³⁶

Estimasi parameter menggunakan model VARIMA (2,0,0)(5,1,0)³⁶ menghasilkan parameter sebanyak 63 parameter. Parameter-parameter tersebut selanjutnya akan diuji signifikansi. Parameter yang tidak signifikan memiliki nilai *p-value* yang bernilai lebih dari α ($\alpha=0,05$). Karena tidak semua parameter berpengaruh signifikan terhadap model, maka dilakukan *restrict*. Perintah *restrict* dilakukan secara bertahap dimulai dari parameter yang memiliki nilai *p-value* yang tertinggi sampai semua parameter bernilai kurang dari α . Setelah dilakukan *restrict* jumlah parameter berkurang sebanyak 30 parameter dan didapatkan 33 parameter yang signifikan terhadap model. 33 parameter ini memiliki *p-value* lebih kecil dari ($\alpha=0,05$). Untuk lebih jelasnya berikut hasil estimasi parameter yang sudah signifikan terhadap model VARIMA (2,0,0)(5,1,0)³⁶ dapat dilihat pada Tabel 4.12.

Tabel 4.12 Hasil Estimasi Parameter Model VARIMA (2,0,0)(5,1,0)³⁶

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	\emptyset_{113}	0.07093	0.021	3.38	0.0008	y3(t-1)
	\emptyset_{211}	-0.10566	0.03986	-2.65	0.0082	y1(t-2)
	\emptyset_{212}	0.14019	0.04085	3.43	0.0006	y2(t-2)
	\emptyset_{213}	0.0454	0.02304	1.97	0.049	y3(t-2)
	$\emptyset_{(36)11}$	-0.6821	0.0457	-14.93	0.0001	y1(t-36)
	$\emptyset_{(36)12}$	-0.08698	0.04346	-2	0.0457	y2(t-36)
	$\emptyset_{(72)11}$	-0.64715	0.03532	-18.32	0.0001	y1(t-72)
	$\emptyset_{(108)11}$	-0.61711	0.03962	-15.58	0.0001	y1(t-108)
	$\emptyset_{(108)12}$	0.15828	0.03964	3.99	0.0001	y2(t-108)
	$\emptyset_{(144)11}$	-0.31649	0.03479	-9.1	0.0001	y1(t-144)
	$\emptyset_{(180)11}$	-0.23624	0.032	-7.38	0.0001	y1(t-180)
	$\emptyset_{(180)12}$	0.08374	0.03971	2.11	0.0352	y2(t-180)
Perak 2 y2(t)	\emptyset_{123}	0.0617	0.01893	3.26	0.0012	y3(t-1)
	\emptyset_{221}	-0.08719	0.03608	-2.42	0.0158	y1(t-2)
	\emptyset_{222}	0.08455	0.03711	2.28	0.0229	y2(t-2)
	\emptyset_{223}	0.05647	0.02078	2.72	0.0067	y3(t-2)
	$\emptyset_{(36)21}$	0.21637	0.0424	5.1	0.0001	y1(t-36)
	$\emptyset_{(36)22}$	-0.98615	0.04424	-22.29	0.0001	y2(t-36)
	$\emptyset_{(72)21}$	0.10356	0.03736	2.77	0.0057	y1(t-72)
	$\emptyset_{(72)22}$	-0.78375	0.03872	-20.24	0.0001	y2(t-72)
	$\emptyset_{(108)22}$	-0.51401	0.03664	-14.03	0.0001	y2(t-108)
	$\emptyset_{(144)21}$	0.0727	0.03391	2.14	0.0323	y1(t-144)
	$\emptyset_{(144)22}$	-0.41143	0.03866	-10.64	0.0001	y2(t-144)
	$\emptyset_{(180)22}$	-0.18823	0.02994	-6.29	0.0001	y2(t-180)

Tabel 4.12 Hasil Estimasi Parameter Model VARIMA (2,0,0)(5,1,0)³⁶
(lanjutan)

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Juanda y3(t)	ϕ_{133}	0.11044	0.02501	4.42	0.0001	y3(t-1)
	ϕ_{231}	-0.07808	0.03313	-2.36	0.0186	y1(t-2)
	ϕ_{233}	0.11736	0.02732	4.3	0.0001	y3(t-2)
	$\phi_{(36)33}$	-0.77374	0.02862	-27.04	0.0001	y3(t-36)
	$\phi_{(72)33}$	-0.65389	0.03537	-18.49	0.0001	y3(t-72)
	$\phi_{(108)33}$	-0.44436	0.03839	-11.57	0.0001	y3(t-108)
	$\phi_{(144)33}$	-0.31311	0.0361	-8.67	0.0001	y3(t-144)
	$\phi_{(180)32}$	-0.08928	0.03486	-2.56	0.0106	y2(t-180)
	$\phi_{(180)33}$	-0.16472	0.02998	-5.49	0.0001	y3(t-180)

Hasil estimasi parameter model VARIMA (2,0,0)(5,1,0)³⁶ yang sudah signifikan kemudian dituliskan matrik koefisien dari model VARIMA (2,0,0)(5,1,0)³⁶ sebagai berikut:

$$\phi_1 = \begin{bmatrix} 0 & 0 & 0,07093 \\ 0 & 0 & 0,0617 \\ 0 & 0 & 0,11044 \end{bmatrix},$$

$$\phi_2 = \begin{bmatrix} -0,10566 & 0,14019 & 0,0454 \\ -0,08719 & 0,08455 & 0,05647 \\ -0,07808 & 0 & 0,11736 \end{bmatrix},$$

$$\phi_{36} = \begin{bmatrix} -0,06821 & -0,08698 & 0 \\ 0,21637 & -0,98615 & 0 \\ 0 & 0 & -0,77374 \end{bmatrix},$$

$$\phi_{72} = \begin{bmatrix} -0,64715 & 0 & 0 \\ 0,10356 & -0,78375 & 0 \\ 0 & 0 & -0,65389 \end{bmatrix},$$


$$\phi_{108} = \begin{bmatrix} -0,61711 & 0,15828 & 0 \\ 0 & -0,51401 & 0 \\ 0 & 0 & -0,44436 \end{bmatrix},$$


$$\Phi_{144} = \begin{bmatrix} -0,31649 & 0 & 0 \\ 0,0727 & -0,41143 & 0 \\ 0 & 0 & -0,31311 \end{bmatrix},$$

$$\Phi_{180} = \begin{bmatrix} -0,23624 & 0,08374 & 0 \\ 0 & -0,18823 & 0 \\ 0 & -0,08928 & -0,16472 \end{bmatrix}.$$

4.2.3 Peramalan Model VAR

Hasil estimasi dari parameter-parameter model yang diperoleh, selanjutnya dilakukan peramalan dengan kelima model. Peramalan ini dilakukan pada data *training* dan *testing*. Hasil peramalan dari kedua model ditampilkan dalam Gambar 4.11.






Gambar 4.11 *Time Series Plot* Hasil Peramalan pada Data *In-sample* untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.

Gambar 4.11 menunjukkan hasil peramalan pada data *in-sample* garis hitam menunjukkan data curah hujan dasarian yang sebenarnya, garis berwarna merah menunjukkan hasil peramalan pada model VARIMA $(2,0,0)(1,1,0)^{36}$, untuk hasil peramalan model VARIMA $(2,0,0)(2,1,0)^{36}$ digambarkan dengan garis hijau, sedangkan untuk garis biru menunjukkan hasil peramalan model VARIMA $(2,0,0)(3,1,0)^{36}$, untuk garis oranye dan merah muda menunjukkan hasil peramalan model VARIMA $(2,0,0)(4,1,0)^{36}$ dan $(2,0,0)(5,1,0)^{36}$. Berdasarkan Gambar 4.11 terlihat bahwa garis peramalan pada kelima model mendekati nilai data curah hujan yang sebenarnya. Hal ini menunjukkan kelima model dapat memprediksi curah hujan dengan baik pada data *in-sample*.

Pada bulan Januari 2014 merupakan bulan awal yang menjadi data *out-sample*. Pada Gambar 4.11 batas antara data *in-sample* dan *out-sample* ditunjukkan dengan garis putus-putus berwarna hitam. Periode data *out-sample* curah hujan dimulai dari bulan Januari 2014 sampai dengan bulan November dasarian pertama tahun 2015. Hasil peramalan terhadap data *out-sampel* ditampilkan pada Gambar 4.12.



Gambar 4.12 *Time Series Plot Hasil Peramalan pada Data Out-sample untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.*

Hasil peramalan untuk data *out-sample* menunjukkan garis hasil peramalan kelima model VARIMA cenderung mengikuti pola data curah hujan sebenarnya. Terlihat pada Gambar 4.12 setiap tahun yaitu pada bulan Januari selalu tercatat tingkat curah hujan tinggi dari pada bulan-bulan lainnya, sehingga dapat dinilai kelima model cukup baik dalam meramalkan data curah hujan dalam periode Januari 2014 sampai dengan akhir bulan November 2015.

4.2.4 Pengujian Asumsi Residual *White Noise*

Estimasi yang telah didapatkan selanjutnya dilakukan pemeriksaan diagnostik yaitu dengan menguji apakah residual memenuhi asumsi identik, independen, dan berdistribusi normal multivariat. Pengujian asumsi *white noise* dilakukan terhadap nilai residual dari peramalan *out-sample*. Pengujian *white noise* ini bertujuan untuk mengetahui apakah residual dari model sudah memenuhi asumsi identik dan independen.

Dalam pemodelan *multivariate time series*, pengujian asumsi *white noise* residual pada penelitian ini menggunakan uji *Multivariate Portmanteau statistics*. Hasil pengujian *Portmanteau* ditampilkan pada Tabel 4.13. dengan hipotesis awal menyatakan residual memenuhi asumsi *white noise*, hipotesis alternative menyatakan sebaliknya, dan nilai α yang sudah ditentukan sebesar 0,05 dapat dilihat bahwa nilai *p-value* pada setiap lag untuk semua model bernilai kurang dari 0,05, sehingga residual untuk data *out-sample* pada kelima model VARIMA belum memenuhi asumsi *white noise*.

Tabel 4.13 Hasil Pengujian *Portmanteau*

Model	Lag	DF	Chi-Square	P-Value
VARIMA (2,0,0)(1,1,0) ³⁶	37	9	519.71	<.0001
	38	18	535.4	<.0001
	39	27	546.24	<.0001
	40	36	562.08	<.0001
	41	45	569.13	<.0001

Tabel 4.13 Hasil Pengujian *Portmanteau* (lanjutan)

Model	Lag	DF	Chi-Square	P-Value
VARIMA (2,0,0)(2,1,0) ³⁶	73	9	832.25	<.0001
	74	18	848.37	<.0001
	75	27	870.64	<.0001
	76	36	881.80	<.0001
	77	45	888.96	<.0001
VARIMA (2,0,0)(3,1,0) ³⁶	109	9	1189.95	<.0001
	110	18	1200.89	<.0001
	111	27	1209.71	<.0001
	112	36	1222.47	<.0001
	113	45	1230.88	<.0001
VARIMA (2,0,0)(4,1,0) ³⁶	145	9	1459.75	<.0001
	146	18	1493.82	<.0001
	147	27	1501.32	<.0001
	148	36	1507.89	<.0001
	149	45	1524.51	<.0001
VARIMA (2,0,0)(5,1,0) ³⁶	181	9	1627.18	<.0001
	182	18	1648.88	<.0001
	183	27	1672.56	<.0001
	184	36	1682.62	<.0001
	185	45	1699.19	<.0001

Lima model VARIMA yang terbentuk semuanya memiliki nilai *p-value* <0,0001. Karena nilai tersebut lebih kecil dari $\alpha=0,05$ maka keputusan hipotesis awal ditolak. Model yang belum memenuhi asumsi *white noise* menunjukkan bahwa model belum optimal. Selanjutnya residual diuji apakah memenuhi asumsi distribusi multivariat atau tidak, dengan menggunakan pengujian normalitas Shapiro Wilk.

4.2.5 Pengujian Asumsi Residual Distribusi Multivariat Normal

Pengujian untuk Selain asumsi *white noise*, asumsi lainnya yang perlu dipenuhi oleh residual model VAR adalah residual berdistribusi multivariat normal. Pengujian asumsi ini menggunakan hipotesis awal yaitu data residual dari model berdistribusi multivariat normal. Sedangkan hipotesis alternatifnya adalah data residual dari model tidak mengikuti distribusi multivariat normal. Pengambilan keputusan dalam pengujian ini didasarkan pada *p-value* yang

dihasilkan. Hipotesis awal akan diterima jika p -value hasil dari pengujian melebihi nilai signifikansi (α) yang sebesar 5% atau 0,05. Hasil pengujian multivariat normal menggunakan Shapiro Wilk disajikan dalam Tabel 4.13.

Tabel 4.13 P -value Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Shapiro Wilk

Model	W	P -value
VARIMA (2,0,0)(1,1,0) ³⁶	0,89979	$2,414 \times 10^{-10}$
VARIMA (2,0,0)(2,1,0) ³⁶	0,91381	$6,835 \times 10^{-9}$
VARIMA (2,0,0)(3,1,0) ³⁶	0,91685	$1,449 \times 10^{-8}$
VARIMA (2,0,0)(4,1,0) ³⁶	0,91996	$3,167 \times 10^{-8}$
VARIMA (2,0,0)(5,1,0) ³⁶	0,9158	$1,115 \times 10^{-8}$

Pengujian menggunakan Shapiro Wilk menghasilkan nilai P -value yang sangat kecil, pengujian multivariat normal pada kelima model VARIMA menghasilkan nilai p -value kurang dari α yang ditetapkan sebesar 0,05. Maka dapat disimpulkan bahwa kelima model VARIMA tersebut tidak memenuhi asumsi distribusi multivariat normal.

4.2.6 Pemilihan Model VAR Terbaik

Kriteria pemilihan model yang digunakan dalam penelitian ini adalah nilai *Akaike's Information Criterion* (AIC) dan *Root Mean Square Error* (RMSE). RMSE didapatkan dari hasil peramalan pada data *out-sample* yang digunakan sebagai data *testing* dan data *in-sample* yang digunakan sebagai data *training*. Perbandingan nilai RMSE data *out-sample* dari kelima model VARIMA ditampilkan pada Tabel 4.14.

Tabel 4.14 Perbandingan Nilai RMSE *Out-sample* Model VAR

Model	Lokasi			RMSE Keseluruhan
	Perak 1	Perak 2	Juanda	
VARIMA (2,0,0)(1,1,0) ³⁶	62,27476	47,49574	56,31422	55,69346
VARIMA (2,0,0)(2,1,0) ³⁶	45,67188	41,1778	48,3448*	45,16175
VARIMA (2,0,0)(3,1,0) ³⁶	40,13447	37,04455*	51,55872	44,75432
VARIMA (2,0,0)(4,1,0) ³⁶	39,41277*	36,83049	49,98336	42,45856*
VARIMA (2,0,0)(5,1,0) ³⁶	41,56055	37,71329	49,19902	43,0895

*RMSE Terkecil

Nilai RMSE Hasil perbandingan nilai RMSE *out-sample* pada Tabel 4.14 menunjukkan nilai RMSE *out sample* terkecil secara keseluruhan adalah pada model VARIMA (2,0,0)(4,1,0)³⁶. Hal ini menunjukkan bahwa model VARIMA (2,0,0)(4,1,0)³⁶ mampu meramalkan curah hujan pada ketiga lokasi pengamatan di Surabaya dengan cukup baik di bandingkan dengan keempat model lainnya. Sehingga dapat diputuskan bahwa model VAR terbaik untuk analisis data curah hujan di lokasi Perak 1, Perak 2, dan Juanda adalah model VARIMA (2,0,0)(4,1,0)³⁶. Sedangkan untuk data *in-sample* diperoleh nilai RMSE seperti yang terlihat pada tabel 4.15.

Tabel 4.15 Perbandingan Nilai RMSE *In-sample* Model VAR

Model	Lokasi			RMSE Keseluruhan
	Perak 1	Perak 2	Juanda	
VARIMA (2,0,0)(1,1,0) ³⁶	51,68639	47,81536	61,82624	54,09953
VARIMA (2,0,0)(2,1,0) ³⁶	48,32845	43,81078	57,15654	50,07293

Tabel 4.15 Perbandingan Nilai RMSE *In-sample* Model VAR (lanjutan)

Model	Lokasi			RMSE Keseluruhan
	Perak 1	Perak 2	Juanda	
VARIMA (2,0,0)(3,1,0) ³⁶	47,38446	42,99214	55,93489	49,06568
VARIMA (2,0,0)(4,1,0) ³⁶	46,63201	41,77437	55,37381	48,25592
VARIMA (2,0,0)(5,1,0) ³⁶	45,83099*	41,19005*	54,31319*	47,4237*

Tabel 4.15 menunjukkan bahwa semakin banyak variabel lag yang ada pada model semakin menghasilkan nilai RMSE yang kecil, sejalan dengan banyaknya parameter yang ada pada model akan menghasilkan RMSE *in-sample* yang semakin kecil. Kriteria pemilihan model terbaik dengan menggunakan RMSE pada data *in-sample* memiliki keputusan yang sama dengan menggunakan AIC. Nilai AIC untuk masing-masing model VAR dapat dilihat pada Tabel 4.16.

Tabel 4.16 Perbandingan Nilai AIC Model VAR

Model	AIC
VARIMA (2,0,0)(1,1,0) ³⁶	22,57926
VARIMA (2,0,0)(2,1,0) ³⁶	22,21052
VARIMA (2,0,0)(3,1,0) ³⁶	21,98236
VARIMA (2,0,0)(4,1,0) ³⁶	21,93971
VARIMA (2,0,0)(5,1,0) ³⁶	21,87046

Nilai AIC ditentukan dengan mempertimbangkan banyaknya parameter yang ada pada model. Pemilihan model terbaik menunjukkan bahwa model terbaik adalah model VARIMA (2,0,0)(5,1,0)³⁶. Adapun dalam memilih model terbaik juga mempertimbangkan adanya prinsip parsimoni yaitu prinsip yang menyatakan model dengan parameter yang sedikit bisa mempunyai kehandalan tinggi. Maka meskipun pada kriteria RMSE *in-sample* dan AIC menyatakan bahwa model VARIMA (2,0,0)(5,1,0)³⁶ adalah model terbaik karena memiliki nilai terkecil pada masing-masing

kriteria. Namun tidak memenuhi prinsip parsimony, selain itu kriteria dengan data *out-sample* lebih diutamakan dari pada data *in-sample*, karena prediksi pada data *out-sample* merupakan hasil yang menyatakan akurasi model sehingga model yang terbaik adalah model VARIMA (2,0,0)(4,1,0)³⁶ dan diperoleh persamaan model VAR untuk curah hujan di masing-masing lokasi. Persamaan model VAR untuk curah hujan pada waktu ke- t untuk lokasi Perak 1 adalah sebagai berikut,

$$y1_t = y1_{t-36} + 0,08576(y1_{t-1} - y1_{t-36}) - 0,1242(y1_{t-2} - y1_{t-38}) + 0,15702(y2_{t-2} - y2_{t-38}) + 0,0564(y3_{t-2} - y3_{t-38}) - 0,73164(y1_{t-36} - y1_{t-72}) - 0,60705(y1_{t-72} - y1_{t-108}) - 0,50632(y1_{t-108} - y1_{t-144}) + 0,14915(y2_{t-108} - y2_{t-144}) - 0,21933(y1_{t-144} - y1_{t-180})$$

Persamaan model VAR untuk curah hujan di lokasi Perak 1 menunjukkan bahwa ketinggian curah hujan di lokasi tersebut tidak hanya dipengaruhi oleh tingkat curah hujan di lokasi itu sendiri namun juga dipengaruhi oleh ketinggian curah hujan yang tercatat di lokasi yang lain. Curah hujan di Perak 1 pada waktu ke- t dipengaruhi oleh ketinggian curah hujan pada 10 hari sebelumnya dan 20 hari sebelumnya pada lokasi yang sama, selain itu juga di pengaruhi ketinggian curah hujan 20 hari sebelumnya di lokasi Perak 2 dan Juanda dan juga terlihat bahwa curah hujan Perak 1 dipengaruhi tingkat curah hujan pada 1, 2, 3 sampai 4 tahun sebelumnya pada lokasi yang sama dan 3 tahun sebelumnya pada tingkat curah hujan di lokasi Perak 2 dan seterusnya. Sedangkan persamaan model VAR untuk curah hujan pada lokasi Perak 2 adalah sebagai berikut,

$$y2_t = y2_{t-36} + 0,07537(y1_{t-1} - y1_{t-36}) - 0,10323(y1_{t-2} - y1_{t-38}) + 0,09673(y2_{t-2} - y2_{t-38}) + 0,0639(y3_{t-2} - y3_{t-38}) + 0,16898(y1_{t-36} - y1_{t-72}) - 0,8977(y2_{t-36} - y2_{t-72}) + 0,07393(y1_{t-72} - y1_{t-108}) - 0,70884(y2_{t-72} - y2_{t-108}) - 0,38961(y2_{t-108} - y2_{t-144}) - 0,20648(y1_{t-144} - y1_{t-180})$$

Persamaan model di atas menunjukkan bahwa curah hujan di Perak 2 pada waktu tertentu dipengaruhi oleh akumulasi ketinggian curah hujan yang tercatat di lokasi tersebut pada 10 hari sebelumnya. Curah hujan pada waktu tertentu juga dipengaruhi oleh tingkat curah hujan pada lokasi Perak 1 yang tercatat pada 10 dan 20 hari sebelumnya. Sama halnya dengan tingkat curah hujan di Perak 2 juga dipengaruhi oleh akumulasi curah hujan 1 sampai dengan 4 tahun sebelumnya pada lokasi yang sama serta akumulasi curah hujan pada 1 dan 2 tahun sebelumnya pada lokasi Perak 1 dan seterusnya. Sedangkan persamaan model matematis untuk ketinggian rata-rata curah hujan di Juanda adalah sebagai berikut,

$$y3_t = y3_{t-36} 0,0767 (y1_{t-1} - y1_{t-36}) + 0,06785 (y3_{t-1} - y3_{t-36}) - 0,09053 (y1_{t-2} - y1_{t-38}) + 0,11712 (y3_{t-2} - y3_{t-38}) - 0,74691 (y3_{t-36} - y3_{t-72}) - 0,07787 (y2_{t-72} - y2_{t-108}) - 0,58127 (y3_{t-72} - y3_{t-108}) - 0,32507 (y3_{t-108} - y3_{t-144}) - 0,16491 (y3_{t-144} - y3_{t-180})$$

Curah hujan di Juanda juga tidak semuanya dipengaruhi oleh tingkat akumulasi curah hujan pada lokasi tersebut namun juga dipengaruhi oleh lokasi lainnya. Pada persamaan diatas terlihat bahwa curah hujan di Juanda dipengaruhi oleh akumulasi curah hujan pada 10 hari sebelumnya di lokasi Perak 1 dan Juanda. Akumulasi curah hujan pada periode 1 sampai dengan 4 tahun sebelumnya di lokasi yang sama juga mempengaruhi curah hujan pada waktu tertentu di Juanda. Tingkat curah hujan pada 2 tahun sebelumnya di Perak 2 juga memiliki pengaruh pada tingginya curah hujan yang terjadi di Juanda dan seterusnya.

4.3 Pemodelan VAR-SVR

Pemodelan VAR-SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan. hal ini bertujuan untuk mendapatkan hasil yang global optimum. Parameter yang dimiliki model SVR ada tiga yaitu parameter epsilon,

sigma, dan cost, untuk mendapatkan parameter yang optimum perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai RMSE yang terkecil.

Model VAR-SVR yang didapatkan dengan menggunakan variabel yang signifikan pada model terbaik VAR. berdasarkan pemilihan model terbaik pada VAR didapatkan model yang terbaik yang menghasilkan RMSE terkecil dari data *out sample* model VARIMA (2,0,0)(4,1,0)³⁶. Pemodelan VAR-SVR untuk masing-masing lokasi dilakukan secara terpisah.

4.3.1 Pemodelan VAR-SVR Perak 1


Hasil pemodelan SVR yang baik akan menghasilkan nilai RMSE pada data *out-sample* yang terkecil. Untuk mendapatkan nilai RMSE yang kecil perlu dilakukan percobaan untuk mengkombinasikan nilai parameter epsilon, gamma, dan *cost* agar didapatkan nilai RMSE yang terbaik. Pada model VAR-SVR untuk perak 1, data yang digunakan adalah sebanyak 1075 data dengan data *out-sample* sebanyak 67 data terakhir seperti yang di tampilkan pada Lampiran 5.

Kombinasi nilai parameter yang digunakan adalah yang pertama untuk parameter epsilon digunakan rentang nilai antara 0,000867 sampai dengan 0.000869 dengan selisih nilai 10^{-7} . Parameter *cost* digunakan nilai antara 2270 sampai 2271 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara $1,2 \times 10^{-7}$ sampai dengan $1,3 \times 10^{-7}$ dengan selisih nilai 10^{-9} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.17.

Tabel 4.17 Hasil Pencarian RMSE Terkecil untuk Perak 1

Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.000867	2270	0.00000013	47.01798568	38.57858
0.000867	2270.5	0.00000013	47.01784587	38.5787
0.000866	2270	0.00000013	47.01797795	38.57873
0.000868	2270	0.00000013	47.01796452	38.57874

Tabel 4.17 menunjukkan Hasil pemodelan menggunakan ketiga parameter tersebut menghasilkan nilai RMSE pada data *out sample* yang paling kecil adalah sebesar 38,6758 dengan menggunakan parameter yang menghasilkan RMSE terkecil tersebut yaitu dengan nilai epsilon 0,000867, nilai cost sebesar 2270, dan nilai sigma sebesar 0,00000013 didapatkan hasil peramalan pada data *in-sample* seperti ditampilkan pada Gambar 4.13.




Gambar 4.13 *Time Series Plot* Hasil Peramalan Model VAR-SVR Perak 1 pada Data *in-sample*

Garis hitam pada Gambar 4.13 menunjukkan nilai yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.13 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model VAR-SVR dengan parameter tersebut dapat memodelkan curah hujan dengan baik. Sedangkan untuk peramalan pada data *out-sample* ditampilkan pada Gambar 4.14. dimana terlihat bahwa hasil peramalan juga cenderung mengikuti pola data curah hujan yang sebenarnya.

Hasil prediksi untuk data *out-sample* menunjukkan hasil yang berbeda dengan data *in-sample*. Dimana terdapat beberapa garis merah yang menyatakan hasil ramalan tidak berhimpit dengan data

sebenarnya. Namun untuk polanya, terlihat bahwa garis berwarna merah cenderung mengikuti pola pada data yang sebenarnya.



Gambar 4.14 Time Series Plot Hasil Peramalan Model VAR-SVR Perak 1 pada Data *out-sample*.

4.3.2 Pemodelan VAR-SVR Perak 2


Ada tiga nilai parameter yang digunakan pada pemodelan VAR-SVR untuk Perak 2 yaitu parameter epsilon digunakan rentang nilai antara 0,000865 sampai dengan 0.00087 dengan selisih nilai 10^{-6} . Parameter *cost* digunakan nilai antara 2100 sampai 2101 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara $1,09 \times 10^{-7}$ sampai dengan $1,095 \times 10^{-7}$ dengan selisih nilai 10^{-9} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.18.

Tabel 4.18 Hasil Pencarian RMSE Terkecil untuk Perak 2

Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.000865	2100.1	0.000000109	42.56279	34.03217
0.000867	2100.3	0.000000109	42.56259	34.03218
0.000868	2100.2	0.000000109	42.56269	34.03219
0.000869	2100.1	0.000000109	42.56278	34.0322
0.000869	2100.3	0.000000109	42.56261	34.0322


Tabel 4.18 menunjukkan bahwa hasil pemodelan menggunakan ketiga parameter tersebut menghasilkan nilai RMSE pada data *out-*

sample yang paling kecil adalah sebesar 34,03217 dengan menggunakan parameter yang menghasilkan RMSE terkecil tersebut yaitu dengan nilai epsilon 0,000865, nilai cost sebesar 2100,1, dan nilai sigma sebesar 0,000000109 didapatkan hasil peramalan pada data *in-sample* seperti ditampilkan pada Gambar 4.15.



Gambar 4.15 *Time Series Plot* Hasil Peramalan Model VAR-SVR Perak 2 pada Data *in-sample*

Time series plot untuk hasil peramalan model VAR-SVR disimbolkan garis hitam pada Gambar 4.15 menunjukkan nilai curah hujan yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan. Terlihat pada Gambar 4.15 bahwa data hasil peramalan berhimpit dengan data curah hujan yang sebenarnya. Sedangkan untuk peramalan pada data *out-sample* ditampilkan pada Gambar 4.16. dimana terlihat bahwa hasil peramalan cenderung mengikuti pola data curah hujan yang sebenarnya namun tidak berhimpit.



Gambar 4.16 Time Series Plot Hasil Peramalan Model VAR-SVR Perak 2 pada Data *out-sample*.

4.3.3 Pemodelan VAR-SVR Juanda


Pada pemodelan VAR-SVR untuk Juanda, kombinasi nilai parameter yang digunakan untuk parameter epsilon digunakan rentang nilai antara 0,00085 sampai dengan 0.00087 dengan selisih nilai 10^{-6} . Parameter *cost* digunakan nilai antara 3000 sampai 3001 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara $1,07 \times 10^{-7}$ sampai dengan $1,09 \times 10^{-7}$ dengan selisih nilai 10^{-10} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.19.

Tabel 4.19 Hasil Pencarian RMSE Terkecil untuk Juanda

Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.00087	3000.5	0.000000108	55.15088	47.75915
0.00087	3001	0.000000108	55.15077	47.75915
0.00086	3001	0.000000108	55.15076	47.75916
0.00085	3001	0.000000108	55.15077	47.75922
0.00086	3000.5	0.000000108	55.15086	47.75927


Tabel 4.19 menunjukkan bahwa hasil pemodelan menggunakan ketiga parameter tersebut menghasilkan nilai RMSE pada data *out sample* yang paling kecil adalah sebesar 47,75915 dengan

menggunakan parameter yang menghasilkan RMSE terkecil tersebut yaitu dengan nilai epsilon 0,00087, nilai cost sebesar 3000,5, dan nilai sigma sebesar 0,000000108 didapatkan hasil peramalan seperti ditampilkan pada Gambar 4.17.



Gambar 4.17 *Time Series Plot* Hasil Peramalan Model VAR-SVR Juanda pada Data *in-sample*

Time series plot untuk hasil peramalan model VAR-SVR disimbolkan garis hitam pada Gambar 4.17 menunjukkan nilai curah hujan yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.17 bahwa garis merah cenderung mengikuti pola dari garis hitam dan berhimpit. Hal ini menunjukkan model VAR-SVR dengan parameter tersebut dapat memodelkan curah hujan di Juanda dengan cukup baik. Sedangkan untuk peramalan pada data *out-sample* ditampilkan pada Gambar 4.18. dimana terlihat bahwa hasil peramalan cenderung mengikuti pola namun tidak berhimpit pada data curah hujan yang sebenarnya.



Gambar 4.18 *Time Series Plot* Hasil Peramalan Model VAR-SVR Juanda pada Data *out-sample*.

4.4 Pemodelan *Generalized Space Time Autoregressive* (GSTAR)

Pemodelan menggunakan metode *Generalized Space Time Auto Regressive* (GSTAR) merupakan pemodelan untuk data *time series* yang memperhatikan faktor lokasi. Faktor lokasi ini ditunjukkan dengan adanya pembobotan yang diberikan pada masing-masing variabel. Terdapat tiga jenis bobot yang digunakan dalam analisis ini, yaitu bobot seragam, bobot invers jarak, dan bobot normalisasi korelasi silang.

Identifikasi dalam pemodelan GSTAR memiliki proses yang sama dengan tahap identifikasi dalam pemodelan VAR dalam menentukan orde model. Maka dari itu, orde model GSTAR yang digunakan dalam analisis ini sama dengan orde dalam model VAR yaitu terdapat 7 lag yang signifikan untuk masing-masing lokasi. Orde spasial yang digunakan dalam pemodelan GSTAR dibatasi pada orde spasial 1. Sehingga model GSTAR yang digunakan dalam analisis curah hujan di Perak 1, Perak 2, dan Juanda adalah GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$. Karena terdapat 7 lag yang signifikan di masing-masing lokasi, serta adanya variabel bobot, maka pemodelan GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ ini secara keseluruhan menggunakan 42 variabel. Analisis model GSTAR ini

juga menggunakan data *in sample* dan *out sample* dengan pembagian data yang sama seperti dalam pemodelan VAR.

Estimasi parameter yang banyak digunakan dalam pemodelan GSTAR adalah *ordinary least square* (OLS) dan *generalized least square* (GLS). Estimasi parameter OLS digunakan untuk data yang residual antar data tersebut tidak saling berkorelasi atau independen, apabila data yang digunakan mempunyai residual yang saling berkorelasi akan menghasilkan estimator yang tidak efisien. Untuk mengetahui apakah residual antar variabel saling berkorelasi atau tidak dapat dilakukan dengan pengujian *white noise* pada residual pemodelan GSTAR hasil estimasi parameter dengan OLS. Pengujian *white noise* dapat dilakukan dengan melihat nilai AIC residual dari model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ pada Tabel 4.19.

Tabel 4.19 AIC Residual dari Model GSTAR
 $([1,2,36,72,108,144,180]_1)-I(1)^{36}$

Lag	Bobot Seragam		Bobot Invers Jarak		Bobot Normalisasi Korelasi Silang	
	MA(0)	MA(1)	MA(0)	MA(1)	MA(0)	MA(1)
AR(0)	21.8327	21.8594	21.79534	21.81192	21.83306	21.85932
AR(1)	21.84191	21.85509	21.79327	21.80638	21.84188	21.8547
AR(2)	21.82781*	21.83946	21.7833*	21.79402	21.82785*	21.83957
AR(3)	21.83767	21.84273	21.79522	21.79776	21.83736	21.84202
AR(4)	21.84188	21.8475	21.79475	21.79936	21.84079	21.84628
AR(5)	21.85021	21.85766	21.80248	21.80926	21.84941	21.85671
AR(6)	21.85255	21.85847	21.80267	21.80965	21.85198	21.8574

*AIC Terkecil

Pada Tabel 4.19 menunjukkan bahwa nilai AIC terkecil terdapat pada orde AR(2) dan MA(0) baik pada GSTAR dengan menggunakan bobot seragam, invers jarak, dan bobot normalisasi korelasi silang. Hal ini menunjukkan bahwa residual saling berkorelasi, maka apabila estimasi parameter pada pemodelan GSTAR dilakukan dengan metode OLS akan dihasilkan estimator yang tidak efisien. Sehingga pada penelitian kali ini digunakan

estimasi parameter dengan metode GLS. GLS adalah penduga parameter regresi yang memperhatikan adanya korelasi dari residual antar persamaan.

Pemodelan GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ pada setiap bobot baik bobot seragam, invers jarak, dan normalisasi korelasi silang digunakan dua macam pemodelan yakni model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dengan menggunakan semua parameter dan dengan menggunakan parameter yang signifikan saja.

4.4.1 Penaksiran Parameter Model GSTAR dengan Bobot Seragam

Bobot seragam dalam pemodelan GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ mengasumsikan bahwa ketinggian curah hujan di lokasi yang satu memiliki pengaruh yang sama terhadap ketinggian curah hujan di lokasi stasiun lainnya. Sehingga matriks bobot seragam yang digunakan dalam analisis ini adalah sebagai berikut,

$$w_{ij} = \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix}$$

Penaksiran parameter untuk pemodelan GSTAR menggunakan *Generalized Least Square*. Model GSTAR dalam penelitian ini menggunakan dua jenis model untuk masing-masing jenis pembobotan yaitu GSTAR dengan menggunakan semua variabel dan model GSTAR dengan menggunakan variabel yang signifikan saja. Untuk mendapatkan variabel yang signifikan dilakukan *restrict* untuk parameter yang tidak signifikan. Perintah ini sama halnya pada perintah *restrict* yang ada pada proses *restrict* untuk pemodelan VAR, namun pada model GSTAR dilakukan secara sekaligus untuk parameter yang mempunyai *p-value* lebih dari $\alpha=5\%$.

a. Pemodelan GSTAR dengan Bobot Seragam Menggunakan Semua Parameter

Pemodelan GSTAR dengan menggunakan semua parameter dilakukan dengan memasukkan semua variabel, baik yang signifikan maupun yang tidak signifikan ke dalam model, dan diperoleh persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dalam bentuk matriks sebagai berikut,

$$\begin{aligned}
 & \begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} \\
 &= \begin{pmatrix} \begin{bmatrix} 0,036959 & 0 & 0 \\ 0 & 0,002207 & 0 \\ 0 & 0 & 0,091871 \end{bmatrix} \\ + \begin{bmatrix} 0,090124 & 0 & 0 \\ 0 & 0,095705 & 0 \\ 0 & 0 & 0,066187 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} 0,009620 & 0 & 0 \\ 0 & -0,02122 & 0 \\ 0 & 0 & 0,106184 \end{bmatrix} \\ + \begin{bmatrix} 0,052689 & 0 & 0 \\ 0 & 0,064048 & 0 \\ 0 & 0 & -0,07056 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} -0,84377 & 0 & 0 \\ 0 & -0,085682 & 0 \\ 0 & 0 & -0,74559 \end{bmatrix} \\ + \begin{bmatrix} 0,104504 & 0 & 0 \\ 0 & 0,110538 & 0 \\ 0 & 0 & 0,002426 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} -0,73616 & 0 & 0 \\ 0 & -0,74770 & 0 \\ 0 & 0 & -0,62083 \end{bmatrix} \\ + \begin{bmatrix} 0,094306 & 0 & 0 \\ 0 & 0,058108 & 0 \\ 0 & 0 & -0,04230 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} -0,59344 & 0 & 0 \\ 0 & -0,57783 & 0 \\ 0 & 0 & -0,41069 \end{bmatrix} \\ + \begin{bmatrix} 0,187515 & 0 & 0 \\ 0 & 0,097197 & 0 \\ 0 & 0 & 0,022274 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix}
 \end{aligned}$$

$$\begin{aligned}
& + \left(\begin{bmatrix} -0,38437 & 0 & 0 \\ 0 & -0,38330 & 0 \\ 0 & 0 & -0,28582 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} 0,101041 & 0 & 0 \\ 0 & 0,061627 & 0 \\ 0 & 0 & -0,00853 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} \\
& + \left(\begin{bmatrix} -0,24612 & 0 & 0 \\ 0 & -0,22808 & 0 \\ 0 & 0 & -0,13763 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} 0,114379 & 0 & 0 \\ 0 & 0,042881 & 0 \\ 0 & 0 & -0,08680 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}.
\end{aligned}$$

b. Pemodelan GSTAR dengan Bobot Seragam Menggunakan Parameter yang Signifikan

Pemodelan GSTAR dengan menggunakan parameter yang signifikan saja dilakukan dengan memasukkan variabel yang signifikan ($p\text{-value} < \alpha=5\%$) kedalam model. Dengan menggunakan variabel yang signifikan tersebut didapatkan hasil estimasi parameter sebagai berikut.

Tabel 4.20 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Seragam

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 1 y1(t)	$\emptyset_{(36)10}$	-0.8181	0.026303	-31.1	<.0001	y1(t-36)
	$\emptyset_{(72)10}$	-0.70134	0.031523	-22.25	<.0001	y1(t-72)
	$\emptyset_{(108)10}$	-0.56707	0.036033	-15.74	<.0001	y1(t-108)
	$\emptyset_{(144)10}$	-0.34766	0.032201	-10.8	<.0001	y1(t-144)
	$\emptyset_{(180)10}$	-0.23321	0.028578	-8.16	<.0001	y2(t-180)
	\emptyset_{111}	0.105488	0.025126	4.2	<.0001	v1(t-1)
	$\emptyset_{(108)11}$	0.062066	0.025331	2.45	0.0145	v1(t-108)
	$\emptyset_{(180)11}$	0.061079	0.025731	2.37	0.0178	v1(t-180)

Tabel 4.20 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Seragam (lanjutan)

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 2 y2(t)	$\emptyset_{(36)20}$	-0.85426	0.027128	-31.49	<.0001	y2(t-36)
	$\emptyset_{(72)20}$	-0.73089	0.031345	-23.32	<.0001	y2(t-72)
	$\emptyset_{(108)20}$	-0.55716	0.034794	-16.01	<.0001	y2(t-108)
	$\emptyset_{(144)20}$	-0.36857	0.032229	-11.44	<.0001	y2(t-144)
	$\emptyset_{(180)20}$	-0.21718	0.026401	-8.23	<.0001	y2(t-180)
	\emptyset_{121}	0.087419	0.022079	3.96	<.0001	v2(t-1)
	$\emptyset_{(36)21}$	0.050656	0.022054	2.3	0.0218	v2(t-36)
Juanda y3(t)	\emptyset_{130}	0.111252	0.024044	4.63	<.0001	y3(t-1)
	\emptyset_{230}	0.090366	0.024982	3.62	0.0003	y3(t-2)
	$\emptyset_{(36)30}$	-0.77961	0.028671	-27.19	<.0001	y3(t-36)
	$\emptyset_{(72)30}$	-0.66093	0.035276	-18.74	<.0001	y3(t-72)
	$\emptyset_{(108)30}$	-0.44589	0.038582	-11.56	<.0001	y3(t-108)
	$\emptyset_{(144)30}$	-0.31639	0.036013	-8.79	<.0001	y2(t-144)
	$\emptyset_{(180)30}$	-0.15513	0.030668	-5.06	<.0001	y3(t-180)
	\emptyset_{231}	-0.08164	0.033142	-2.46	0.0139	v3(t-2)
	$\emptyset_{(180)31}$	-0.09086	0.034306	-2.65	0.0082	v3(t-180)

Berdasarkan Tabel 4.20 diketahui bahwa pada lokasi stasiun Perak 1, Perak 2, dan Juanda tingkat curah hujan juga dipengaruhi oleh tingkat curah hujan pada lokasi lain dengan estimasi jarak antara stasiun satu dengan yang lain sama. Estimasi parameter yang dihasilkan diperoleh persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dalam bentuk matriks sebagai berikut,

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.111252 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} +$$

$$\begin{aligned}
& \begin{bmatrix} 0.105488 & 0 & 0 \\ 0 & 0.087419 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \\
& \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.090366 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & -0.08164 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \\
& \begin{bmatrix} -0.81810 & 0 & 0 \\ 0 & -0.85426 & 0 \\ 0 & 0 & -0.77961 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} \\
& + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0.050656 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \\
& \begin{bmatrix} -0.70134 & 0 & 0 \\ 0 & -0.73089 & 0 \\ 0 & 0 & -0.66093 \end{bmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} + \\
& \begin{bmatrix} -0.56707 & 0 & 0 \\ 0 & -0.55716 & 0 \\ 0 & 0 & -0.44589 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \\
& \begin{bmatrix} 0.062066 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \\
& \begin{bmatrix} -0.34766 & 0 & 0 \\ 0 & -0.36857 & 0 \\ 0 & 0 & -0.31639 \end{bmatrix} \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} + \\
& \begin{bmatrix} -0.23321 & 0 & 0 \\ 0 & -0.21718 & 0 \\ 0 & 0 & -0.15513 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \\
& \begin{bmatrix} 0.061079 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & -0.09086 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-180) \\ Z_2(t-180) \\ Z_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}
\end{aligned}$$

4.4.2 Penaksiran Parameter Model GSTAR dengan Bobot Invers Jarak

Penerapan bobot invers jarak dilakukan dalam analisis pemodelan GSTAR ini karena metode pembobotan ini mengasumsikan bahwa hubungan ketinggian curah hujan di lokasi yang satu dengan lainnya dipengaruhi oleh jauh dekatnya jarak yang dimiliki antara kedua lokasi tersebut. Jarak yang jauh cenderung

memiliki bobot yang lebih rendah dibandingkan dengan jarak antara dua lokasi yang berdekatan. Gambar 4.19 menampilkan posisi dari ketiga lokasi pencatatan curah hujan beserta dengan jarak antar lokasinya.

Gambar 4.19 menunjukkan bahwa lokasi Juanda merupakan lokasi yang paling jauh dari kedua lokasi lainnya. Jarak terjauh dari ketiga lokasi tersebut adalah jarak antara Juanda dengan Perak 2. Berdasarkan jarak antara masing-masing ketiga lokasi ini dapat dibentuk sebuah matriks pembobot dengan menormalisasikan nilai invers dari jarak antar lokasi.

Jarak terjauh adalah jarak antara Perak 2 dan Juanda yaitu sepanjang 20,03 km, untuk jarak antara Perak 1 dan Juanda adalah 18,57 km. jarak yang berdekatan adalah antara Perak 1 dan Perak 2 yaitu hanya 2,43 km. Hasil perhitungan matriks pembobot dengan metode invers jarak adalah sebagai berikut,

$$w_{ij} = \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,0108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$



Gambar 4.19 Jarak Antar Lokasi Pencatatan Curah Hujan

a. Pemodelan GSTAR dengan Bobot Invers Jarak Menggunakan Semua Parameter

Semua parameter, baik yang signifikan maupun yang tidak signifikan dimasukkan ke dalam model, maka diperoleh persamaan model GSTAR $([1,2,36,72,108,144,180]_1) - I(1)^{36}$ dalam bentuk matriks sebagai berikut

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} 0,061338 & 0 & 0 \\ 0 & 0,005340 & 0 \\ 0 & 0 & 0,069080 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} +$$

$$\begin{bmatrix} 0,056182 & 0 & 0 \\ 0 & 0,088348 & 0 \\ 0 & 0 & 0,081767 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} -0,04133 & 0 & 0 \\ 0 & -0,049724 & 0 \\ 0 & 0 & 0,093272 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} \\ + \begin{bmatrix} 0,103430 & 0 & 0 \\ 0 & -0,01792 & 0 \\ 0 & 0 & -0,06311 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \begin{bmatrix} -0,74128 & 0 & 0 \\ 0 & -0,93045 & 0 \\ 0 & 0 & -0,77205 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} \\ + \begin{bmatrix} -0,01196 & 0 & 0 \\ 0 & 0,178209 & 0 \\ 0 & 0 & 0,022642 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \begin{bmatrix} -0,71374 & 0 & 0 \\ 0 & -0,74702 & 0 \\ 0 & 0 & -0,77205 \end{bmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} \\ + \begin{bmatrix} 0,073498 & 0 & 0 \\ 0 & 0,065019 & 0 \\ 0 & 0 & -0,02536 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} + \begin{bmatrix} -0,64951 & 0 & 0 \\ 0 & -0,48740 & 0 \\ 0 & 0 & -0,44491 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} \\ + \begin{bmatrix} 0,241851 & 0 & 0 \\ 0 & 0,002951 & 0 \\ 0 & 0 & 0,049201 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \begin{bmatrix} -0,38321 & 0 & 0 \\ 0 & -0,36267 & 0 \\ 0 & 0 & -0,30750 \end{bmatrix} \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} \\ + \begin{bmatrix} 0,098721 & 0 & 0 \\ 0 & 0,039796 & 0 \\ 0 & 0 & 0,009009 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} + \begin{bmatrix} -0,27787 & 0 & 0 \\ 0 & -0,16557 & 0 \\ 0 & 0 & -0,15742 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} \\ + \begin{bmatrix} 0,154752 & 0 & 0 \\ 0 & -0,00869 & 0 \\ 0 & 0 & -0,07090 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix}$$

$$\begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}$$

b. Pemodelan GSTAR dengan Bobot Invers jarak Menggunakan Parameter yang Signifikan

Pemodelan GSTAR dengan menggunakan parameter yang signifikan dilakukan dengan memasukkan parameter-parameter yang signifikan saja kedalam model, parameter yang signifikan adalah parameter yang memiliki nilai *p-value* kurang dari nilai $\alpha=5\%$. Tabel 4.19 menunjukkan hasil estimasi parameter untuk model GSTAR dengan bobot invers jarak menggunakan parameter yang signifikan.

Tabel 4.21 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Invers Jarak

Lokasi	Parameter	Estimasi	Std Error	<i>t-value</i>	<i>P-value</i>	Variabel
Perak 1 y1(t)	$\emptyset_{(36)10}$	-0.78331	0.028697	-27.3	<.0001	y1(t-36)
	$\emptyset_{(72)10}$	-0.70241	0.031565	-22.25	<.0001	y1(t-72)
	$\emptyset_{(108)10}$	-0.58913	0.03889	-15.15	<.0001	y1(t-108)
	$\emptyset_{(144)10}$	-0.34542	0.032194	-10.73	<.0001	y1(t-144)
	$\emptyset_{(180)10}$	-0.23161	0.031857	-7.27	<.0001	y2(t-180)
	\emptyset_{211}	0.04758	0.017133	2.78	0.0056	v1(t-2)
	$\emptyset_{(108)11}$	0.113454	0.037232	3.05	0.0024	v1(t-108)
	$\emptyset_{(180)11}$	0.09458	0.037913	2.49	0.0128	v1(t-180)
Perak 2 y2(t)	$\emptyset_{(36)20}$	-0.89779	0.030201	-29.73	<.0001	y2(t-36)
	$\emptyset_{(72)20}$	-0.73084	0.031449	-23.24	<.0001	y2(t-72)
	$\emptyset_{(108)20}$	-0.52983	0.036653	-14.46	<.0001	y2(t-108)
	$\emptyset_{(144)20}$	-0.36427	0.032328	-11.27	<.0001	y2(t-144)
	$\emptyset_{(180)20}$	-0.17988	0.028038	-6.42	<.0001	y2(t-180)
	$\emptyset_{(36)21}$	0.114233	0.031143	3.67	0.0003	v2(t-36)

Tabel 4.21 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Invers Jarak (lanjutan)

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Juanda y ³ (t)	\emptyset_{130}	0.070824	0.022598	3.13	0.0018	y3(t-1)
	\emptyset_{230}	0.067996	0.022867	2.97	0.003	y3(t-2)
	$\emptyset_{(36)30}$	-0.77753	0.028725	-27.07	<.0001	y3(t-36)
	$\emptyset_{(72)30}$	-0.66208	0.035366	-18.72	<.0001	y3(t-72)
	$\emptyset_{(108)30}$	-0.44465	0.038629	-11.51	<.0001	y3(t-108)
	$\emptyset_{(144)30}$	-0.31807	0.036159	-8.8	<.0001	y2(t-144)

Tabel 4.21 menunjukkan pada lokasi stasiun Juanda tingkat curah hujan tidak dipengaruhi oleh tingkat curah hujan di lokasi lain dengan walaupun dengan estimasi jarak lokasi antar stasiun berbeda sesuai dengan jarak yang sebenarnya. Dengan menggunakan bobot invers jarak dan mengeluarkan parameter yang tidak signifikan pada model diperoleh persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dalam bentuk matriks sebagai berikut,

$$\begin{aligned}
 \begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} &= \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,070824 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,067996 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} \\
 &+ \begin{bmatrix} 0,047580 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \\
 &\begin{bmatrix} -0,78331 & 0 & 0 \\ 0 & -0,89779 & 0 \\ 0 & 0 & -0,77753 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \\
 &\begin{bmatrix} 0 & 0 & 0 \\ 0 & 0,114233 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \\
 &\begin{bmatrix} -0,70241 & 0 & 0 \\ 0 & -0,73084 & 0 \\ 0 & 0 & -0,66208 \end{bmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} + \\
 &\begin{bmatrix} -0,58913 & 0 & 0 \\ 0 & -0,52983 & 0 \\ 0 & 0 & -0,44465 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} +
 \end{aligned}$$

$$\begin{aligned}
& \begin{bmatrix} 0,113454 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \\
& \begin{bmatrix} -0,34542 & 0 & 0 \\ 0 & -0,36427 & 0 \\ 0 & 0 & -0,31807 \end{bmatrix} \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} + \\
& + \begin{bmatrix} -0,23161 & 0 & 0 \\ 0 & -0,17988 & 0 \\ 0 & 0 & -0,18508 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \\
& \begin{bmatrix} 0,094580 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,884286 & 0,115714 \\ 0,891808 & 0 & 0,108192 \\ 0,518912 & 0,481088 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-180) \\ Z_2(t-180) \\ Z_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}
\end{aligned}$$

4.4.3 Penaksiran Parameter Model GSTAR dengan Bobot Normalisasi Korelasi Silang

Model GSTAR dengan pembobotan metode normalisasi korelasi silang ini mengasumsikan bahwa keterkaitan tingginya curah hujan antar lokasi lebih dipengaruhi oleh tinggi rendahnya korelasi yang dimiliki dari data curah hujan pada lokasi tersebut. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antar lokasi pada lag yang bersesuaian, dengan lag yang digunakan dibatasi pada lag 1. Matriks hasil perhitungan bobot normalisasi korelasi silang untuk analisis ini adalah

$$w_{ij} = \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix}$$

a. Pemodelan GSTAR dengan Bobot Normalisasi Korelasi Silang Menggunakan Semua Parameter

Semua parameter pada model GSTAR dengan menggunakan bobot normalisasi korelasi silang, diperoleh persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dalam bentuk matriks sebagai berikut

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} 0,029448 & 0 & 0 \\ 0 & 0,009893 & 0 \\ 0 & 0 & 0,090649 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix}$$

$$\begin{aligned}
& + \begin{bmatrix} 0,077424 & 0 & 0 \\ 0 & 0,097055 & 0 \\ 0 & 0 & 0,073251 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} 0,003983 & 0 & 0 \\ 0 & -0,01690 & 0 \\ 0 & 0 & 0,106813 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \\
& \begin{bmatrix} 0,049622 & 0 & 0 \\ 0 & -0,070080 & 0 \\ 0 & 0 & -0,07651 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \begin{bmatrix} -0,85021 & 0 & 0 \\ 0 & -0,84681 & 0 \\ 0 & 0 & -0,74799 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} \\
& + \begin{bmatrix} 0,086338 & 0 & 0 \\ 0 & 0,109136 & 0 \\ 0 & 0 & 0,003123 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \begin{bmatrix} -0,77424 & 0 & 0 \\ 0 & -0,73985 & 0 \\ 0 & 0 & -0,62218 \end{bmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} \\
& + \begin{bmatrix} 0,080450 & 0 & 0 \\ 0 & 0,056140 & 0 \\ 0 & 0 & -0,04610 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} + \begin{bmatrix} -0,60730 & 0 & 0 \\ 0 & -0,56370 & 0 \\ 0 & 0 & -0,41245 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} \\
& + \begin{bmatrix} 0,164763 & 0 & 0 \\ 0 & 0,096645 & 0 \\ 0 & 0 & 0,027584 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \begin{bmatrix} -0,39174 & 0 & 0 \\ 0 & -0,37506 & 0 \\ 0 & 0 & -0,28715 \end{bmatrix} \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} \\
& + \begin{bmatrix} 0,087901 & 0 & 0 \\ 0 & 0,060722 & 0 \\ 0 & 0 & -0,00802 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix}
\end{aligned}$$

$$\begin{aligned}
& \begin{bmatrix} Y_1(t-144) \\ Y_2(t-144) \\ Y_3(t-144) \end{bmatrix} + \begin{bmatrix} -0,25326 & 0 & 0 \\ 0 & -0,22014 & 0 \\ 0 & 0 & -0,13912 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} \\
& + \begin{bmatrix} 0,099065 & 0 & 0 \\ 0 & -0,040480 & 0 \\ 0 & 0 & -0,09399 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \\
& \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}.
\end{aligned}$$

b. Pemodelan GSTAR dengan Bobot Normalisasi Korelasi Silang Menggunakan Variabel yang signifikan

Pemodelan GSTAR dengan menggunakan parameter yang signifikan saja dilakukan dengan cara memodelkan data sebanyak beberapa kali tanpa melibatkan parameter yang tidak signifikan sampai didapatkan model dengan semua parameter yang mempunyai nilai *p-value* kurang dari 0.05 atau signifikan. Sehingga didapatkan hasil estimasi parameter seperti pada Tabel 4.22.

Tabel 4.22 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Normalisasi Korelasi Silang.

Lokasi	Parameter	Estimasi	Std Error	<i>t-value</i>	<i>P-value</i>	Variabel
Perak 1 y1(t)	$\emptyset_{(36)10}$	-0.81419	0.026208	-31.07	<.0001	y1(t-36)
	$\emptyset_{(72)10}$	-0.69679	0.031477	-22.14	<.0001	y1(t-72)
	$\emptyset_{(108)10}$	-0.57013	0.036435	-15.65	<.0001	y1(t-108)
	$\emptyset_{(144)10}$	-0.34571	0.032131	-10.76	<.0001	y1(t-144)
	$\emptyset_{(180)10}$	-0.21989	0.028616	-7.68	<.0001	y1(t-180)
	\emptyset_{111}	0.077018	0.020398	3.78	0.0002	v1(t-1)
	\emptyset_{211}	0.063042	0.020425	3.09	0.0021	v1(t-2)
	$\emptyset_{(108)11}$	0.055954	0.022091	2.53	0.0115	v1(t-108)
	$\emptyset_{(180)11}$	0.054753	0.022438	2.44	0.0149	v1(t-180)

Tabel 4.22 Hasil Penaksiran Parameter Model GSTAR Menggunakan Parameter Signifikan pada Bobot Normalisasi Korelasi Silang(lanjutan)

Lokasi	Parameter	Estimasi	Std Error	t-value	P-value	Variabel
Perak 2 y2(t)	$\emptyset_{(36)20}$	-0.84879	0.026945	-31.5	<.0001	y2(t-36)
	$\emptyset_{(72)20}$	-0.72905	0.031338	-23.26	<.0001	y2(t-72)
	$\emptyset_{(108)20}$	-0.55416	0.034951	-15.86	<.0001	y2(t-108)
	$\emptyset_{(144)20}$	-0.36629	0.032219	-11.37	<.0001	y2(t-144)
	$\emptyset_{(180)20}$	-0.20078	0.025977	-7.73	<.0001	y2(t-180)
	\emptyset_{121}	0.084846	0.024504	3.46	0.0006	v2(t-1)
	\emptyset_{221}	0.069633	0.024509	2.84	0.0046	v2(t-2)
	$\emptyset_{(36)21}$	0.053627	0.023701	2.26	0.0239	v2(t-36)
Juanda y3(t)	\emptyset_{130}	0.103666	0.023972	4.32	<.0001	y3(t-1)
	\emptyset_{230}	0.089536	0.024136	3.71	0.0002	y3(t-2)
	$\emptyset_{(36)30}$	-0.78084	0.02877	-27.14	<.0001	y3(t-36)
	$\emptyset_{(72)30}$	-0.6609	0.035349	-18.7	<.0001	y3(t-72)
	$\emptyset_{(108)30}$	-0.44531	0.038715	-11.5	<.0001	y3(t-108)
	$\emptyset_{(144)30}$	-0.31721	0.036142	-8.78	<.0001	y3(t-144)
	$\emptyset_{(180)30}$	-0.18268	0.029076	-6.28	<.0001	y3(t-180)

Sama seperti pada hasil estimasi model GSTAR dengan bobot invers jarak, tingkat curah hujan di Juanda tidak dipengaruhi oleh parameter bobot normalisasi korelasi silang yang menyatakan korelasi silang antar lokasi pada lag yang berseuaian. Bentuk persamaan matriks untuk pemodelan GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dengan menggunakan parameter yang signifikan adalah sebagai berikut,


$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,103666 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} \begin{bmatrix} 0,077018 & 0 & 0 \\ 0 & 0,084846 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$


$$\begin{aligned}
& \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \\
& \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,089536 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \begin{bmatrix} 0,063042 & 0 & 0 \\ 0 & 0,069633 & 0 \\ 0 & 0 & 0 \end{bmatrix} \\
& \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-2) \\ Y_2(t-2) \\ Y_3(t-2) \end{bmatrix} + \\
& \begin{bmatrix} -0,81419 & 0 & 0 \\ 0 & -0,84879 & 0 \\ 0 & 0 & -0,78084 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \\
& \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0,053627 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-36) \\ Y_2(t-36) \\ Y_3(t-36) \end{bmatrix} + \\
& \begin{bmatrix} -0,69679 & 0 & 0 \\ 0 & -0,72905 & 0 \\ 0 & 0 & -0,66090 \end{bmatrix} \begin{bmatrix} Y_1(t-72) \\ Y_2(t-72) \\ Y_3(t-72) \end{bmatrix} + \\
& \begin{bmatrix} -0,57013 & 0 & 0 \\ 0 & -0,55416 & 0 \\ 0 & 0 & -0,44531 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \\
& \begin{bmatrix} 0,055954 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-108) \\ Y_2(t-108) \\ Y_3(t-108) \end{bmatrix} + \\
& \begin{bmatrix} -0,34571 & 0 & 0 \\ 0 & -0,36629 & 0 \\ 0 & 0 & -0,31721 \end{bmatrix} \begin{bmatrix} Z_1(t-144) \\ Z_2(t-144) \\ Z_3(t-144) \end{bmatrix} + \\
& \begin{bmatrix} -0,21989 & 0 & 0 \\ 0 & -0,20078 & 0 \\ 0 & 0 & -0,18268 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \\
& \begin{bmatrix} 0,054753 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,70582 & 0,548459 \\ 0,421571 & 0 & 0,476172 \\ 0,441988 & 0,465317 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-180) \\ Y_2(t-180) \\ Y_3(t-180) \end{bmatrix} + \begin{bmatrix} a_1(t) \\ a_2(t) \\ a_3(t) \end{bmatrix}
\end{aligned}$$

4.4.4 Peramalan Model GSTAR

Setelah didapatkan hasil estimasi parameter dari model GSTAR $([1,2,36,72,108,144,180], -I(1))^{36}$ untuk semua jenis bobot, selanjutnya hasil estimasi tersebut digunakan untuk meramalkan

curah hujan pada data *in-sample* dan *out-sample*. Peramalan atau prediksi untuk model GSTAR dilakuakn secara manual. Hasil peramalan pada data *in-sampel* menunjukkan bahwa hasil peramalan menggunakan bobot seragam yang mengasumsikan tingkat curah hujan di lokasi satu dengan yang lainnya sama memberikan prediksi yang berbeda jauh dengan tingkat curah hujan sebenarnya, tidak hanya pada model yang menggunakan semua parameter, pada model yang hanya menggunakan parameter yang signifikan juga memberikan hasil yang sama seperti yang ditampilkan pada Gambar 4.20.






Gambar 4.20 *Time Series Plot* Hasil Peramalan data *In-sample* Model GSTAR di Perak 1 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.

Garis hijau menunjukkan data hasil peramalan dengan menggunakan parameter yang signifikan, garis hitam menunjukkan data curah hujan yang sebenarnya, dan garis merah menunjukkan data hasil peramalan menggunakan semua parameter. Hasil peramalan data *in-sample* menunjukkan bahwa hasil peramalan untuk bobot seragam dengan menggunakan semua parameter pada lokasi perak 1 berbeda jauh dengan data curah hujan yang sebenarnya, sedangkan untuk hasil peramalan yang lain cenderung berhimpit dan mengikuti pola.

Peramalan data *out-sample* dilakukan pada periode Januari 2014 sampai dengan dasarian pertama pada bulan November 2015. Peramalan ini menggunakan dua tipe model GSTAR, yaitu model yang memuat semua parameter, dan model yang hanya memuat parameter yang signifikan. Hasil peramalan kedua tipe model GSTAR ini untuk data *out-sample* di lokasi Perak 1 ditampilkan pada Gambar 4.21.



Gambar 4.21 *Time Series Plot* Hasil Peramalan Model GSTAR di Perak 1 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.


Garis warna hitam menunjukkan data yang sebenarnya, sedangkan garis berwarna merah menunjukkan hasil prediksi dari model GSTAR dengan menggunakan semua parameter, dan untuk garis yang berwarna hijau menunjukkan hasil prediksi dari model GSTAR dengan menggunakan parameter yang signifikan saja. Berdasarkan Gambar 4.21 dapat diketahui bahwa hasil peramalan menggunakan bobot seragam dengan melibatkan semua parameter memberikan hasil yang berbeda jauh dengan nilai yang sebenarnya. Hal ini menunjukkan bahwa tingkat curah hujan pada lokasi Perak 1 tidak dipengaruhi oleh tingkat curah hujan di lokasi lain dengan estimasi tingkat curah hujan antar lokasi sama. Sedangkan hasil peramalan menggunakan bobot invers jarak dan normalisasi korelasi silang memberikan hasil yang hampir sama, hal ini menunjukkan bahwa bobot invers jarak dan bobot normalisasi korelasi memberikan kriteria pembobotan yang hampir sama, terlihat dari pola *time series* yang dihasilkan dari kedua jenis bobot yang terlihat mirip.


Perbedaan hasil peramalan menggunakan semua parameter dan hanya menggunakan parameter yang signifikan pada model GSTAR dengan bobot seragam menunjukkan hasil perbedaan peramalan yang sangat mencolok. Terlihat bahwa garis berwarna merah yang menyatakan hasil peramalan model GSTAR dengan menggunakan semua parameter memiliki perbedaan pola yang signifikan terhadap garis hijau yang menunjukkan hasil peramalan dengan menggunakan parameter signifikan. Hasil ramalan untuk pemodelan GSTAR dengan menggunakan parameter yang signifikan lebih baik dari pada garis merah, dapat dilihat dari garis hijau yang cenderung lebih mendekati pola data yang sebenarnya dari pada garis berwarna merah. Sehingga pada bobot seragam nilai estimasi parameter yang signifikan terlihat sangat berpengaruh untuk menghasilkan pemodelan yang lebih baik. Berbeda dengan bobot seragam, hasil peramalan pada bobot invers jarak dan normalisasi korelasi silang memiliki hasil peramalan yang lebih baik dari pada bobot seragam.

Hasil peramalan menggunakan parameter yang signifikan dan semua parameter pada kedua bobot tidak menunjukkan perbedaan yang signifikan. *Plot* untuk hasil peramalan menggunakan bobot

invers jarak dan normalisasi korelasi silang juga menunjukkan pola yang serupa.




Peramalan untuk lokasi Perak 2 pada data *in-sample* dapat dilihat pada Gambar 4.22. hasil peramalan menunjukkan baik model GSTAR dengan menggunakan bobot seragam, invers jarak, maupun normalisasi korelasi silang memberikan hasil yang cukup baik terlihat dari garis hasil peramalan yang berhimpit dengan garis hitam yang menunjukkan data curah hujan yang sebenarnya.





Gambar 4.22 *Time Series Plot* Hasil Peramalan data *In-sample* Model GSTAR di Perak 2 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.

Garis berwarna hijau menunjukkan hasil peramalan menggunakan parameter yang signifikan, sedangkan garis berwarna merah menunjukkan hasil peramalan model GSTAR dengan menggunakan semua parameter. Pada bobot lokasi seragam terlihat bahwa hasil peramalan dengan menggunakan parameter yang signifikan dan tidak signifikan tidak berhimpit, berbeda dengan hasil peramalan untuk bobot lokasi invers jarak dan normalisasi korelasi silang. Kedua bobot tersebut memberikan hasil peramalan yang hampir sama pada data hasil peramalan menggunakan semua parameter dan hasil peramalan dengan parameter yang signifikan saja. *Time series plot* untuk hasil peramalan di lokasi pengamatan Perak 2 pada data *out-sample* dapat dilihat pada Gambar 4.23.






Gambar 4.23 *Time Series Plot* Hasil Peramalan Data *Out-Sample* Model GSTAR di Perak 2 Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.

Gambar 4.23 juga menunjukkan bahwa hasil peramalan menggunakan bobot seragam dengan melibatkan semua parameter memberikan hasil yang tidak mengikuti pola curah hujan yang sebenarnya. Hal ini menunjukkan bahwa tingkat curah hujan pada lokasi Perak 2 tidak dipengaruhi oleh tingkat curah hujan di lokasi lain dengan estimasi pengaruh tingkat curah hujan antar lokasi sama. Sedangkan hasil peramalan menggunakan bobot invers jarak dan normalisasi korelasi silang memberikan hasil yang hampir sama, hal ini menunjukkan bahwa bobot invers jarak dan bobot normalisasi korelasi silang memberikan kriteria pembobotan yang hampir sama, terlihat dari pola *time series* yang dihasilkan dari kedua jenis bobot yang terlihat mirip.

Hasil ramalan untuk pemodelan GSTAR dengan menggunakan parameter yang signifikan lebih baik dari pada garis merah, dapat dilihat dari garis hijau yang cenderung lebih mendekati pola data yang sebenarnya dari pada garis berwarna merah. Sehingga pada bobot seragam nilai estimasi parameter yang signifikan terlihat sangat berpengaruh untuk menghasilkan pemodelan yang lebih baik dari pada model dengan menggunakan semua parameter. Berbeda dengan bobot seragam, hasil peramalan pada bobot invers jarak dan normalisasi korelasi silang memiliki hasil peramalan yang lebih baik dari pada bobot seragam. Hasil peramalan menggunakan parameter yang signifikan dan semua parameter pada kedua bobot tidak menunjukkan perbedaan yang berarti. Begitu juga untuk *plot* hasil peramalan menggunakan bobot invers jarak dan normalisasi silang juga menunjukkan pola yang serupa.


Time series plot untuk data *in sample* pada lokasi Juanda ditampilkan pada Gambar 4.24. Dimana garis hitam menunjukkan data curah hujan yang sebenarnya, garis hijau menunjukkan data hasil peramalan curah hujan dengan menggunakan variabel yang signifikan, dan garis merah menunjukkan hasil peramalan model GSTAR dengan menggunakan semua variabel.




Gambar 4.24 *Time Series Plot* Hasil Peramalan data *In-sample* Model GSTAR di Juanda Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.

Pada bobot lokasi seragam terlihat bahwa hasil peramalan dengan menggunakan variabel yang signifikan dan tidak signifikan tidak berhimpit, berbeda dengan hasil peramalan untuk bobot lokasi invers jarak dan normalisasi korelasi silang. Kedua bobot tersebut memberikan hasil peramalan yang hampir sama pada data hasil peramalan menggunakan semua variabel dan hasil peramalan dengan variabel yang signifikan saja.

Time series plot untuk lokasi pengamatan Juanda menunjukkan hasil yang tidak sama dengan hasil peramalan curah hujan di Perak 1 dan Perak 2, terlihat prediksi curah hujan untuk lokasi Juanda memiliki tingkat curah hujan yang lebih tinggi. *Time series plot* untuk hasil peramalan di lokasi pengamatan Juanda dapat dilihat pada Gambar 4.25.





Gambar 4.25 *Time Series Plot* Hasil Peramalan Model GSTAR di Juanda Menggunakan Bobot (a) Seragam, (b) Invers Jarak, dan (c) Normalisasi Korelasi Silang.

Peramalan menggunakan bobot seragam dengan melibatkan semua parameter memberikan hasil yang berbeda dengan nilai yang sebenarnya. Sedangkan hasil peramalan menggunakan bobot invers jarak dan normalisasi korelasi silang memberikan hasil yang hampir sama, terlihat dari pola *time series* yang dihasilkan dari kedua jenis bobot yang terlihat mirip.

Hasil peramalan menggunakan semua parameter dan hanya menggunakan parameter yang signifikan pada model GSTAR dengan bobot seragam menunjukkan hasil perbedaan peramalan yang signifikan. Terlihat bahwa garis berwarna hijau memiliki perbedaan pola yang signifikan terhadap garis merah yang menunjukkan hasil peramalan dengan menggunakan parameter signifikan. Hasil ramalan untuk pemodelan GSTAR dengan menggunakan parameter yang signifikan cenderung tidak mengikuti pola data curah hujan yang sebenarnya. Berbeda dengan kedua lokasi lain, hasil peramalan pada bobot seragam nilai estimasi parameter yang signifikan terlihat berbeda dengan data sebenarnya. Untuk hasil peramalan pada bobot invers jarak dan normalisasi korelasi silang memiliki hasil peramalan yang lebih baik dari pada bobot seragam. Hasil peramalan menggunakan parameter yang signifikan dan semua parameter pada kedua bobot tidak menunjukkan perbedaan yang berarti. Begitu juga

untuk *plot* hasil peramalan menggunakan bobot invers jarak dan bobot normalisasi silang juga menunjukkan pola yang cenderung sama.

4.4.5 Pengujian Asumsi *White Noise Residual*

Pada pemodelan GSTAR terdapat asumsi yang harus diuji, salah satunya adalah asumsi residual yang identik dan independen atau *white noise*. Pengujian asumsi *white noise* pada pemodelan multivariat dilakukan dengan melihat nilai AIC minimum dari residual model.

a. Model GSTAR dengan Semua Parameter

Nilai AIC minimum dari pemodelan GSTAR dengan melibatkan semua parameter ditampilkan pada Tabel 4.23

Tabel 4.23 AIC Residual dari Model GSTAR
 $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ Menggunakan Semua Parameter

Lag	Bobot Seragam		Bobot Invers Jarak		Bobot Normalisasi Korelasi Silang	
	MA(0)	MA(1)	MA(0)	MA(1)	MA(0)	MA(1)
AR(0)	21.78535*	21.81038	21.77715	21.79937	21.78453*	21.80894
AR(1)	21.792	21.80512	21.78027	21.7934	21.79044	21.80335
AR(2)	21.79067	21.79858	21.77389*	21.78329	21.78959	21.7974
AR(3)	21.80415	21.8083	21.78714	21.79194	21.80292	21.80685
AR(4)	21.80588	21.80845	21.78726	21.79258	21.80442	21.80683
AR(5)	21.81222	21.81996	21.7945	21.80279	21.81067	21.81829
AR(6)	21.81054	21.81787	21.79359	21.80043	21.80919	21.81636
AR(7)	21.81624	21.83009	21.7983	21.81236	21.81467	21.82849
AR(8)	21.83294	21.85264	21.81522	21.83492	21.83133	21.85103
AR(9)	21.85087	21.87072	21.83294	21.85279	21.84933	21.86918
AR(10)	21.85908	21.87908	21.8411	21.8611	21.85759	21.87759

*AIC Terkecil

Suatu model dikatakan *white noise* ketika nilai AIC minimum berada pada orde AR(0) dan MA(0). Pada Tabel 4.23 terlihat bahwa nilai AIC terkecil pada model GSTAR dengan bobot seragam

terdapat pada orde AR(0) dan MA(0), hal ini menunjukkan bahwa model GSTAR dengan bobot seragam memenuhi asumsi residual *white noise*. Sama seperti pada model GSTAR dengan bobot seragam, model dengan menggunakan bobot normalisasi korelasi silang juga menunjukkan bahwa model memenuhi asumsi residual *white noise*. Sedangkan AIC minimum pada model GSTAR dengan menggunakan bobot invers jarak terjadi pada orde AR(2) MA(0) sehingga model tidak memenuhi asumsi residual *white noise*.

b. Model GSTAR dengan Parameter Signifikan

Nilai AIC minimum dari pemodelan GSTAR dengan melibatkan parameter yang signifikan ditampilkan pada Tabel 4.24.

Tabel 4.24 AIC Residual dari Model GSTAR
 $([1,2,36,72,108,144,180]_1) - I(1)^{36}$ Menggunakan Parameter Signifikan

Lag	Bobot Seragam		Bobot Invers Jarak		Bobot Normalisasi Korelasi Silang	
	MA(0)	MA(1)	MA(0)	MA(1)	MA(0)	MA(1)
AR(0)	21.80977	21.82607	21.82972	21.83587	21.81083	21.82641
AR(1)	21.80872	21.82503	21.81158	21.82379	21.80894	21.82528
AR(2)	21.79422*	21.80379	21.79568*	21.80264	21.80459*	21.81197
AR(3)	21.80738	21.81251	21.80972	21.81491	21.81837	21.82371
AR(4)	21.8098	21.81395	21.81317	21.81807	21.81934	21.82395
AR(5)	21.81859	21.82472	21.82019	21.82578	21.82854	21.83414
AR(6)	21.81705	21.82328	21.81758	21.82685	21.82787	21.83492
AR(7)	21.82242	21.83649	21.82231	21.83877	21.83154	21.84647
AR(8)	21.83931	21.85901	21.84158	21.86129	21.84919	21.86889
AR(9)	21.85776	21.87761	21.85876	21.87861	21.86809	21.88794
AR(10)	21.86539	21.88539	21.86587	21.88587	21.87495	21.89495

*AIC Terkecil

Pada Tabel 4.24 terlihat bahwa nilai AIC terkecil pada model GSTAR dengan menggunakan ketiga jenis bobot terdapat pada orde AR(2) dan MA(0), hal ini menunjukkan bahwa model GSTAR dengan menggunakan semua bobot tidak memenuhi asumsi residual

white noise. maka dalam pemilihan model terbaiknya akan lebih diberatkan pada perbandingan nilai RMSE terkecil dari hasil peramlan data *out-sampel*.

4.4.6 Pengujian Asumsi Residual Distribusi Multivariat Normal

Distribusi multivariat normal merupakan salah satu asumsi yang harus dipenuhi dalam pemodelan GSTAR. Hipotesis awal yang digunakan dalam pengujian asumsi ini adalah data residual dari model berdistribusi multivariat normal. Sedangkan hipotesis alternatifnya adalah data residual tidak berdistribusi multivariat normal.

a. Model GSTAR dengan Semua Parameter

Pengambilan keputusan dari pengujian ini dapat dilakukan secara visual dengan melihat nilai *p-value* dari pengujian menggunakan Shapiro Wilk hasil pengujian dari model GSTAR menggunakan semua variabel dengan ketiga bobot lokasi ditampilkan dalam Tabel 4.25.

Pengambilan keputusan dari pengujian ini dapat dilakukan dengan melihat nilai *p-value* dari pengujian menggunakan Shapiro Wilk hasil pengujian dari model GSTAR menggunakan semua parameter dengan ketiga bobot lokasi ditampilkan dalam Tabel 4.25.

Tabel 4.25 *P-value* Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Semua Parameter

Bobot	W	<i>P-value</i>
Seragam	0,8851	$2,2 \times 10^{-16}$
Invers Jarak	0,8831	$2,2 \times 10^{-16}$
Normalisasi Korelasi Silang	0,8853	$2,2 \times 10^{-16}$

Pengujian menggunakan Shapiro Wilk menghasilkan nilai *P-value* yang sangat kecil, pengujian multivariat normal pada model GSTAR ($[1,2,36,72,108,144,180]_1$)-I(1)³⁶ dengan menggunakan ketiga jenis bobot semua model menghasilkan nilai *p-value* kurang dari α

yang ditetapkan sebesar 0,05. Maka dapat disimpulkan bahwa semua model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dengan menggunakan parameter yang signifikan tersebut tidak memenuhi asumsi residual berdistribusi multivariat normal.

b. Model GSTAR dengan Parameter Signifikan

Pengambilan keputusan dari pengujian ini dilakukan dengan melihat nilai *p-value* dari pengujian menggunakan Shapiro Wilk hasil pengujian pada model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ menggunakan parameter signifikan dengan ketiga bobot lokasi ditampilkan dalam Tabel 4.26.

Tabel 4.26 *P-value* Hasil Pengujian Asumsi Distribusi Multivariat Normal Menggunakan Parameter Signifikan

Bobot	W	<i>P-value</i>
Seragam	0,8789	$2,2 \times 10^{-16}$
Invers Jarak	0,8771	$2,2 \times 10^{-16}$
Normalisasi Korelasi Silang	0,8798	$2,2 \times 10^{-16}$

Tabel 4.22 menampilkan *p-value* dari hasil pengujian distribusi multivariat normal pada data residual dari model GSTAR yang menggunakan parameter signifikan. *P-value* yang dihasilkan dalam pengujian asumsi distribusi multivariat normal untuk ketiga bobot lokasi memiliki nilai yang lebih kecil dari α , sehingga dapat disimpulkan bahwa residual dari model GSTAR dengan parameter signifikan belum mengikuti distribusi multivariat normal untuk ketiga bobot lokasi yang digunakan.

4.4.7 Pemilihan Model GSTAR Terbaik

Kriteria yang digunakan dalam pemilihan model GSTAR terbaik sama halnya dengan pemilihan model terbaik pada VAR yaitu *Root Mean Square Error* (RMSE) dari hasil peramalan data *out-sample* dan *in-sample*. Model yang terbaik akan ditunjukkan oleh nilai RMSE terkecil. Hasil perhitungan nilai RMSE data *in-sample*

dari model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dengan ketiga bobot lokasi ditampilkan dalam Tabel 4.27.

Tabel 4.27 Perbandingan Nilai RMSE *In-sample* dari Model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$

Lokasi	Pemodelan dengan Semua Parameter			Pemodelan dengan Parameter yang Signifikan		
	Seragam	Invers Jarak	Korelasi Silang	Seragam	Invers Jarak	Korelasi Silang
Perak 1	335.542	46.3263	46.0726*	74.5869	46.497	46.112
Perak 2	56.1332	41.8465	42.3982	71.5679	42.016	41.778*
Juanda	63.636	55.6884	54.1556*	124.691	54.761	54.653
Total	199.824	48.2992	47.795*	93.511	48.05	47.815

*RMSE terkecil

Tabel 4.27 menunjukkan bahwa nilai RMSE terkecil pada data *in-sample* secara keseluruhan terdapat pada model GSTAR dengan bobot normalisasi korelasi silang menggunakan semua parameter. Sedangkan untuk nilai RMSE pada data *out-sample* dapat dilihat pada Tabel 4.28.

Tabel 4.28 Perbandingan Nilai RMSE *Out-sample* dari Model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$

Lokasi	Pemodelan dengan Semua Parameter			Pemodelan dengan Parameter yang Signifikan		
	Seragam	Invers Jarak	Korelasi Silang	Seragam	Invers Jarak	Korelasi Silang
Perak 1	271,2868	62,2626	61,7325	68,7310	61,7713	61,0599*
Perak 2	55,1563*	56,1579	56,1562	66,2657	56,1511	55,6316
Juanda	79,1952	75,5786*	76,776	109,9268	76,0599	76,1471
Total	166,2688	66,3322	66,2888*	84,0611	65,2016	64,8629*

*RMSE terkecil

Hasil perbandingan nilai RMSE pada Tabel 4.28 menunjukkan bahwa model terbaik yang dapat digunakan untuk meramal ketinggian curah hujan di lokasi Perak 1 adalah model GSTAR yang

menggunakan parameter yang signifikan menggunakan bobot normalisasi korelasi silang. Sedangkan untuk lokasi Perak 2 dan Juanda masing-masing baik diramalkan menggunakan model GSTAR dengan bobot seragam dan invers jarak dan melibatkan semua parameter.

Nilai RMSE terkecil dari hasil peramalan baik dengan menggunakan model GSTAR yang menggunakan semua parameter secara keseluruhan maupun yang menggunakan parameter yang signifikan saja, secara keseluruhan model yang menghasilkan peramalan ketinggian curah hujan terbaik adalah model GSTAR yang menggunakan bobot normalisasi korelasi silang yang menggunakan parameter signifikan saja dalam model tersebut, karena model inilah yang menghasilkan nilai RMSE terkecil secara keseluruhan pada data *out-sample*. Namun terdapat kriteria lain untuk menentukan model terbaik, yaitu dengan menggunakan AIC. Nilai AIC untuk masing-masing model GSTAR dapat dilihat pada Tabel 4.29.

Tabel 4.29 Perbandingan Nilai AIC Model GSTAR
 $([1,2,36,72,108,144,180]_1)-I(1)^{36}$

Bobot	AIC dengan Semua Parameter	AIC dengan Parameter Signifikan
Seragam	21,8579	21,8799
Invers Jarak	21,8481*	21,8798*
Normalisasi Korelasi Silang	21,8565	21,8809

*AIC Terkecil

Nilai AIC ditentukan dengan mempertimbangkan banyaknya parameter yang ada pada model. Semakin kecil nilai AIC menunjukkan model semakin baik. Berdasarkan Tabel 4.29 didapatkan nilai AIC terkecil adalah pada model GSTAR dengan menggunakan bobot invers jarak, baik dengan menggunakan semua parameter maupun parameter yang signifikan saja. Sehingga berdasarkan kriteria nilai AIC, model terbaik adalah model GSTAR dengan bobot invers jarak dan menggunakan semua parameter. Tetapi sama halnya pada pemilihan model terbaik VAR, karena nilai AIC

merupakan nilai hasil dari data *trainng* maka kriteria pemilihan model terbaik yang digunakan adalah RMSE data *out sample* sehingga model yang terbaik adalah model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ dengan bobot normalisasi korelasi silang dan menggunakan parameter yang signifikan. Persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ setelah dikembalikan ke data asli seperti sebelum *didifferencing* menggunakan parameter yang signifikan dengan bobot normalisasi korelasi silang pada lokasi Perak1 adalah sebagai berikut:

$$y1_t = y1_{t-36} + 0,0543608(y2_{t-1} - y2_{t-37}) + 0,042241(y3_{t-1} - y3_{t-37}) + 0,0444963(y2_{t-2} - y2_{t-38}) + 0,034576(y3_{t-2} - y3_{t-38}) + (-0,81419(y1_{t-36} - y1_{t-72})) + (-0,69679(y1_{t-72} - y1_{t-108})) + (-0,57013(y1_{t-108} - y1_{t-144})) + 0,039493(y2_{t-108} - y2_{t-144}) + 0,030688(y3_{t-108} - y3_{t-144}) + (-0,34571(y1_{t-144} - y1_{t-180})) + (-0,21989(y1_{t-180} - y1_{t-216})) + 0,038646(y2_{t-180} - y2_{t-216}) + 0,0300298(y3_{t-180} - y3_{t-216}) + a1_t.$$

Terlihat pada persamaan diatas bahwa curah hujan di lokasi Perak 1 di pengaruhi oleh curah hujan dilokasi lainnya, seperti Perak 2 dan Junda dari 3 sampai 6 tahun yang lalu dan seterusnya. Untuk persamaan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ menggunakan parameter yang signifikan pada lokasi Perak 2 dengan bobot normalisasi korelasi silang adalah sebagai berikut:

$$y2_t = y2_{t-36} + 0,035769(y1_{t-1} - y1_{t-37}) + 0,040401(y3_{t-1} - y3_{t-37}) + 0,029355(y2_{t-2} - y2_{t-38}) + 0,033157(y3_{t-2} - y3_{t-38}) + (-0,84879(y2_{t-36} - y2_{t-72})) + 0,022607(y1_{t-36} - y1_{t-72}) + 0,0255357(y3_{t-36} - y3_{t-72}) + (-0,72905(y2_{t-72} - y2_{t-108})) + (-0,55416(y2_{t-108} - y2_{t-144})) + (-0,36629(y2_{t-144} - y2_{t-180})) + (-0,20078(y2_{t-180} - y2_{t-216})) + a2_t,$$

Tingkat curah hujan di lokasi perak 2 juga tidak hanya dipengaruhi oleh lokasi tersebut, melainkan juga dipengaruhi oleh lokasi perak 1 dan Juanda bahkan juga dipengaruhi oleh tingkat curah hujan di beberapa periode waktu yang lalu. Namun berbeda dengan dua lokasi tersebut yaitu Perak 1 dan Perak 2, curah hujan di lokasi Juanda tidak dipengaruhi oleh tingkat curah hujan di lokasi lainnya. Model GSTAR $([1,2,36,72,108,144,180]_I)-I(1)^{36}$ menggunakan parameter yang signifikan pada lokasi Juanda dengan bobot normalisasi korelasi silang adalah sebagai berikut:

$$y3_t = y3_{t-36} + 0,103666(y3_{t-1} - y3_{t-37}) + 0,089536(y3_{t-2} - y3_{t-38}) + (-0,78084(y3_{t-36} - y3_{t-72})) + (-0,6609(y3_{t-72} - y3_{t-108})) + (-0,44531(y3_{t-108} - y3_{t-144})) + (-0,31721(y3_{t-144} - y3_{t-180})) + (-0,18268(y3_{t-180} - y3_{t-216})) + a3_t.$$

4.5 Pemodelan GSTAR-SVR

Pemodelan GSTAR-SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan. hal ini bertujuan untuk mendapatkan hasil yang global optimum. Parameter yang dimiliki model SVR ada tiga yaitu parameter epsilon, sigma, dan cost, untuk mendapatkan parameter yang optimum perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai RMSE yang terkecil.

Model GSTAR-SVR yang didapatkan dengan menggunakan variabel yang signifikan pada model terbaik GSTAR. berdasarkan pemilihan model terbaik pada GSTAR didapatkan model yang terbaik yang menghasilkan RMSE terkecil dari data *out sample* model GSTAR $([1,2,36,72,108,144,180]_I)-I(1)^{36}$ dengan bobot normalisasi korelasi silang dan menggunakan parameter yang signifikan. Pemodelan GSTAR-SVR untuk masing-masing lokasi dilakukan secara terpisah.

4.5.1 Pemodelan GSTAR-SVR Perak 1


Hasil pemodelan SVR yang baik akan menghasilkan nilai RMSE pada data *outsample* yang terkecil. Untuk mendapatkan nilai RMSE yang kecil perlu dilakukan percobaan untuk mengkombinasikan nilai parameter epsilon, gamma, dan *cost* agar didapatkan nilai RMSE yang terbaik. Pada model GSTAR-SVR untuk perak 1, data yang digunakan adalah sebanyak 1039 data dengan data *out-sample* sebanyak 67 data terakhir.

Kombinasi nilai parameter yang digunakan adalah yang pertama untuk parameter epsilon digunakan rentang nilai antara 0,00005 sampai dengan 0.00009 dengan selisih nilai 10^{-5} . Parameter *cost* digunakan nilai antara 350 sampai 355 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara 5×10^{-7} sampai dengan 7×10^{-7} dengan selisih nilai 10^{-7} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.30.

Tabel 4.30 Hasil Pencarian RMSE Terkecil untuk Perak 1


Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.00009	355	0.0000005	46.84146	41.68467
0.00006	355	0.0000005	46.84146	41.68477
0.00007	355	0.0000005	46.84145	41.6848
0.00005	355	0.0000005	46.84146	41.68486
0.00008	355	0.0000005	46.84144	41.68488

Tabel 4.30 menunjukkan nilai RMSE pada data *out sample* yang paling kecil adalah sebesar 41,68467, yaitu dengan nilai epsilon 0,00009, nilai *cost* sebesar 355, dan nilai sigma sebesar 0,0000005 didapatkan hasil peramalan pada data *out sample* seperti ditampilkan pada Gambar 4.26.



Gambar 4.26 *Time Series* Hasil Peramalan Model GSTAR-SVR Perak 1

Garis hitam pada Gambar 4.26 menunjukkan nilai yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.26 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTAR-SVR dengan parameter tersebut dapat memodelkan curah hujan dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada Gambar 4.27.



Gambar 4.27 *Time Series Plot* Hasil Peramalan pada Data *out-sample* Model GSTAR-SVR Perak 1

Hasil peramalan pada data *out-sample* di Perak 1 menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan

data curah hujan yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.


4.5.2 Pemodelan GSTAR-SVR Perak 2

Nilai parameter yang digunakan pada pemodelan GSTAR-SVR untuk Perak 2 yaitu parameter epsilon digunakan rentang nilai antara 10^{-8} sampai dengan 10^{-7} dengan selisih nilai 10^{-8} . Parameter *cost* digunakan nilai antara 390 sampai 450 dengan selisih nilai 10. Sedangkan untuk nilai sigma digunakan nilai antara 3×10^{-7} sampai dengan 6×10^{-7} dengan selisih nilai 10^{-7} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.30.

Tabel 4.31 Hasil Pencarian RMSE Terkecil untuk Perak 2


Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.00000008	450	0.0000003	42.93431	32.90443
0.00000003	450	0.0000003	42.93432	32.90445
0.00000006	450	0.0000003	42.93431	32.90445
0.00000001	450	0.0000003	42.9343	32.90446
0.00000007	450	0.0000003	42.9343	32.90448

Tabel 4.31 menunjukkan bahwa hasil pemodelan menggunakan ketiga parameter tersebut menghasilkan nilai RMSE pada data *out sample* yang paling kecil adalah sebesar 32,90443 dengan menggunakan parameter yang menghasilkan RMSE terkecil tersebut yaitu dengan nilai epsilon 0,00000008, nilai cost sebesar 450, dan nilai sigma sebesar 0,0000003 didapatkan hasil peramalan pada data *in-sample* ditampilkan pada Gambar 4.28.



Gambar 4.28 *Time Series Plot* Hasil Peramalan Data *In-sample* Model GSTAR-SVR Perak 2

Time series plot untuk hasil peramalan model GSTAR-SVR disimbolkan garis hitam pada Gambar 4.28 menunjukkan nilai curah hujan yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.28 bahwa garis merah cenderung mengikuti pola dari garis hitam. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada Gambar 4.29.



Gambar 4.29 *Time Series Plot* Hasil Peramalan pada Data *out-sample* Model GSTAR-SVR Perak 2

Hasil peramalan pada data *out-sample* di Perak 2 menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan

data curah hujan yang sebenarnya, namun tidak berhimpit dengan data yang sebenarnya.


4.5.3 Pemodelan GSTAR-SVR Juanda

Pada pemodelan GSTAR-SVR untuk Juanda, kombinasi nilai parameter yang digunakan untuk parameter epsilon digunakan rentang nilai antara 10^{-9} sampai dengan 8×10^{-9} dengan selisih nilai 10^{-9} . Parameter *cost* digunakan nilai antara 280 sampai 281 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara 7×10^{-7} sampai dengan 9×10^{-7} dengan selisih nilai 7×10^{-8} . Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Tabel 4.31.

Tabel 4.32 Hasil Pencarian RMSE Terkecil untuk Juanda


Epsilon	Cost	Sigma	RMSE <i>In sample</i>	RMSE <i>Out sample</i>
0.000000001	280	0.00000007	54.39433	50.33458
0.000000001	280	0.000000071	54.38469	50.31764
0.000000001	280	0.000000072	54.37223	50.29859
0.000000001	280	0.000000073	54.35658	50.2871
0.000000001	280	0.000000074	54.34027	50.2704

Tabel 4.32 menunjukkan bahwa hasil pemodelan menggunakan ketiga parameter tersebut menghasilkan nilai RMSE pada data *out sample* yang paling kecil adalah sebesar 50,33458 dengan menggunakan parameter yang menghasilkan RMSE terkecil tersebut yaitu dengan nilai epsilon 10^{-9} , nilai cost sebesar 280, dan nilai sigma sebesar 0,00000007 didapatkan hasil peramalan seperti ditampilkan pada Gambar 4.30.



Gambar 4.30 *Time Series Plot* Hasil Peramalan pada Data *In-sample* Model GSTAR-SVR Juanda

Time series plot untuk hasil peramalan model GSTAR-SVR disimbolkan garis hitam pada Gambar 4.30 menunjukkan nilai curah hujan yang sebenarnya, sedangkan garis merah menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.30 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTAR-SVR dengan parameter tersebut dapat memodelkan curah hujan di Juanda dengan baik. Sedangkan untuk peramalan curah hujan pada data *out sample* ditampilkan pada Gambar 4.31.



Gambar 4.31 *Time Series Plot* Hasil Peramalan pada Data *out-sample* Model GSTAR-SVR Juanda



Hasil peramalan pada data *out-sample* di Juanda menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data curah hujan yang sebenarnya, namun juga tidak terlihat berhimpit sama halnya dengan lokasi lainnya


4.6 Peramalan Satu Tahun Kedepan

Peramalan untuk keempat model yaitu pada model VAR, GSTAR, VAR—SVR, dan GSTAR-SVR dilakukan untuk meramalkan curah hujan selama satu tahun kedepan, pada setiap lokasi stasiun pengamatan di Surabaya.

4.6.1 Peramalan Model VAR Satu Tahun Kedepan

Model VAR terbaik yang telah didapatkan, digunakan untuk melakukan meramalkan tingkat curah hujan yang akan terjadi selama satu tahun kedepan terhitung dari akhir tahun 2015.







Gambar 4.32 Hasil Peramalan pada Model VAR untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.

Hasil peramalan untuk setiap lokasi menggunakan model VAR didapatkan pola tingkat curah hujan yang tinggi pada bulan November hingga April, dan menurun pada awal bulan Mei. Keadaan ini terjadi pada lokasi Perak 1 dan Perak 2, sedangkan untuk lokasi Juanda lebih berfluktuasi pada peralihan musim hujan ke musim kemarau.

4.6.2 Peramalan Model GSTAR Satu Tahun Kedepan

Model GSTAR terbaik yang telah didapatkan, digunakan untuk melakukan meramalkan tingkat curah hujan yang akan terjadi selama satu tahun kedepan terhitung dari akhir tahun 2015.






Gambar 4.33 Hasil Peramalan pada Model gstAR untuk Lokasi (a) Perak 1; (b) Perak 2; (c) Juanda.

Hasil peramalan untuk setiap lokasi menggunakan model GSTAR didapatkan pola tingkat curah hujan yang tinggi pada bulan November hingga April, dan menurun pada awal bulan Mei. Keadaan ini terjadi pada lokasi Perak 1 dan Perak 2, sedangkan untuk lokasi Juanda lebih berfluktuasi pada peralihan musim hujan ke musim kemarau dan mulai meningkat kembali di awal bulan November.

4.6.3 Peramalan Model VAR-SVR Satu Tahun Kedepan

Model VAR-SVR dengan parameter-parameter optimum yang telah didapatkan, digunakan untuk melakukan meramalkan tingkat curah hujan yang terjadi selama satu tahun kedepan terhitung dari akhir tahun 2015.




Gambar 4.34 Hasil Peramalan pada Model VAR-SVR untuk Lokasi
(a)Perak 1; (b) Perak 2; (c) Juanda.


Hasil peramalan pada pemodelan VAR-SVR, lebih berfluktuasi dari pada hasil peramalan untuk model yang lain. Keadaan curah

hujan tertinggi pada lokasi Perak 1, Perak 2 , dan Juanda terjadi pada bulan Desember sampai Maret.

4.6.4 Peramalan Model GSTAR-SVR Satu Tahun Kedepan

Model GSTAR- SVR dengan parameter-parameter optimum yang telah didapatkan, digunakan untuk melakukan meramalkan tingkat curah hujan yang terjadi selama satu tahun kedepan terhitung dari akhir tahun 2015.





Gambar 4.35 Hasil Peramalan pada Model GSTAR-SVR untuk Lokasi (a)Perak 1; (b) Perak 2; (c) Juanda.

Hasil peramalan untuk model GSTAR-SVR memiliki hasil peramalan yang sedikit berbeda dengan pemodelan lainnya, terutama pada lokasi Perak 1, tingkat curah hujan di akhir tahun tepatnya pada bulan November dan Akhir Desember terjadi curah hujan yang rendah dan mengalami kenaikan tingkat curah hujan sampai bulan Maret. Sedangkan untuk lokasi lain seperti Perak 2 dan Juanda cenderung memiliki pola yang sama dengan hasil ramalan model VAR dan GSTAR.

(Halaman ini sengaja dikosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis yang sudah dijelaskan, didapatkan beberapa kesimpulan untuk menjawab tujuan yang telah ditetapkan.

1. Model VAR yang sesuai untuk meramalkan surah hujan di ketiga lokasi yaitu Perak 1, Perak 2, dan Juanda adalah model VARIMA (2,0,0)(4,1,0)³⁶. Model VAR yang sesuai dipilih berdasarkan kriteria pemilihan model terbaik dari nilai RMSE terkecil dan nilai AIC terkecil, namun karena nilai AIC dan RMSE tidak memberikan kesimpulan yang sama maka pemilihan model terbaik didasarkan dari nilai RMSE data *out sample* dimana nilai RMSE terkecil menunjukkan model dapat meramalkan tingkat curah hujan lebih baik dari pada model yang lain yang memiliki RMSE lebih besar.
2. Model GSTAR terbaik, baik untuk model GSTAR dengan menggunakan semua parameter maupun menggunakan parameter yang signifikan saja adalah model GSTAR ([1,2,36,72,108,144,180]₁)-I(1)³⁶ dengan menggunakan bobot normalisasi korelasi silang, pemilihan model terbaik ini juga dilihat dari nilai RMSE terkecil pada data *out sampel*. Sedangkan untuk model yang terbaik diantara model GSTAR 1,2,36,72,108,144,180]₁)-I(1)³⁶ dengan menggunakan semua parameter atau menggunakan parameter yang signifikan saja, nilai RMSE terkecil pada data *out sample* terdapat pada GSTAR dengan menggunakan parameter yang signifikan. Sehingga model yang digunakan untuk pemodelan GSTAR-SVR adalah model GSTAR 1,2,36,72,108,144,180]₁)-I(1)³⁶ dengan bobot normalisasi korelasi silang yang menggunakan parameter yang signifikan.

3. Model VARIMA $(2,0,0)(4,1,0)^{36}$ dibandingkan dengan model GSTAR $([1,2,36,72,108,144,180]_1)-I(1)^{36}$ berdasarkan kriteria RMSE *out-sample* menunjukkan bahwa model VARIMA $(2,0,0)(4,1,0)^{36}$ lebih baik dari pada GSTAR.
4. Model VAR-SVR relatif memiliki nilai RMSE *out sample* yang lebih kecil dari pada model GSTAR-SVR, sehingga dapat disimpulkan bahwa model terbaik untuk meramalkan curah hujan di ketiga wilayah Surabaya adalah menggunakan model VAR-SVR.

5.2 Saran

Dalam penelitian tugas akhir ini tidak memperhatikan adanya data *outlier* sehingga disarankan untuk penelitian selanjutnya menggunakan metode yang bisa memperhatikan data *outlier* maupun variabel klimatologi lain sebagai input *series* seperti pada model VARIMAX dan GSTARX.

DAFTAR PUSTAKA

- Alva, J. A., & Estrada, E. G. (2009). A Generalization of Shapiro Wilk's Test for Multivariate Normality. *Communications in Statistics – Theory and Methods Journal*, 1870-1883.
- Borovkova, S., Lopuhaä, H.P., & Ruchjana, B.N., (2008), Consistency and Asymptotic Normality of Least Squares Estimators in Generalized STAR Models, *Statistica Neerlandica*. Vol.62, hal. 482-508.
- Dhoriva U, W., & Suhartono, S. (2009). Peramalan Deret Waktu Multivariat Seasonal Pada Data Pariwisata Dengan Model VAR-GSTAR. In *Seminar Nasional Matematika dan Pendidikan Matematika 2009*. Jurusan Pendidikan Matematika FMIPA UNY.
- Diani, Setiawan, & Suhartono. (2013). Pemodelan VAR-NN dan GSTAR-NN untuk Peramalan Curah Hujan di Kabupaten Malang. *Jurnal Sains dan Seni POMITS* Vol. 2, No.1, 2337-3520.
- Gunn, S. R.,(1998). *Support Vector Machine for Classification and Regression*: University of Southampton.
- Haerdle, W.K, Prastyo, D.D. & Hafner, C.M. (2014). *Support Vector Machines with Evolutionary Model Selection for Default Prediction*, in *The Oxford Handbook of Applied Nonparametric and Semiparametric Econometrics and Statistics*, eds. Racine, JS, Su, L, and Ullah, A, Oxford University Press, 346-373.
- Hannan, E.J. (1970). *Multiple time series*. New York: John Wiley.
- Hong, W.C. (2008). Electric Load Forecasting by Support Vector Model. *Applied Mathematical Modelling* Vol. 33, 2444-2454.
- Johnson, R. A. & Winchern, D. W. (2007). *Applied Multivariate Statistical Analysis*. United States of America : Pearson Education, Inc.
- Machmudin, A, & Ulama, B. S.S. (2012). Peramalan Temperatur udara di Kota Surabaya dengan Menggunakan ARIMA

- dan Artificial Neural Network. *Jurnal Sains dan Seni POMITS* Vol. 1, No.1, 2301-928X.
- Montgomery, D. C. (2009). *Introduction to Statistical Quality Control Sixth Edition*. United States of America : John Wiley & Sons, Inc.
- Muhtaram A. L.(2011) *Metris Community* [Online] [.http://www.metriscommunity.com/pengertian data mining-konsep pdf/](http://www.metriscommunity.com/pengertian_data_mining-konsep_pdf/).
- Nugroho. (2008). *Support Vector Machine: Paradigma Baru dalam softcomputing dan Aplikasinya, Konferensi Nasional Sistem & Informatika*. Bali
- Nurhayati S., Kusriani, & Luthfi, E. T. (2015). Prediksi Mahasiswa Drop Out Menggunakan Metode Support Vector Machine.*Jurnal Ilmiah SISFOTENIKA* Vol. 5, No. 1.
- Prasetyo, E. (2014). *Data Mining Konsep dan Aplikasi Menggunakan MATLAB*, Yogyakarta: Andi.
- Santoso, B.(2007). *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*, Yogyakarta: Graha Ilmu.
- Saputro, & Dewi, D.L. (2009). Memprediksi Curah Hujan (Data Spatio-Temporal) dengan Metode Bayesian Networks.*Prosiding Seminar Nasional Penelitian, Pendidikan, dan Penerapan MIPA* .
- Sims, C.A. (1972). Money, Income, and Causality. *American Economic Review* Vol. 62, pp. 540-552.
- Tiao, G.C., & Box, G.E.P. (1981). *Modeling Multiple Time Series with Applications*, J. Amer. Statist. Assoc.
- Tsay, R.S. (2014). *Multivariate Time Series Analysis*. Chicago: John Wiley, Inc.
- Walpole, R.E., dan Meyers, R.H. (1995). *Ilmu Peluang dan Statistika untuk Insinyur dan Ilmuwan (ed ke-4)*. R.K. Sembiring (Trans). Bandung : Penerbit ITB. (Buku asli dipublikasikan 1972-1989).
- Wei, W. W.S. (2006). *TIME SERIES ANALYSIS: Univariate and Multivariate Methode Second Edition*. United States of America: Pearson Education, Inc.

- Yasin.H, Prahutama. A, & Utami. T. W. (2014). Prediksi Harga Saham Menggunakan Support Vector Regression dengan Algoritma Grid Search.*Media Statistika*. Vol. 7 No. 1.
- Zheng, F. & Zhong, S. (2011).*Time Series Forecasting Using A Hybrid RBF Neural Network and AR Model Based on Binomial Smoothing*, *World Academy of Science, Engineering and Technology*, 75, 1471-1475.

LAMPIRAN

Lampiran 1

Data Akumulasi Curah Hujan Dasarian di Lokasi Perak 1, Perak 2, dan Juanda.

Bulan	Dasarian	Perak 1	Perak 2	Juanda
Jan-81	1	186.600	220.300	153.9
	2	49.400	35.300	38.8
	3	130.300	143.600	290.4
Feb-81	1	50.500	44.200	149.9
	2	38.500	73.500	169.3
	3	43.300	93.300	238.0
Mar-81	1	12.600	12.800	143.9
	2	19.400	73.100	30.9
	3	22.400	27.700	177.2
Apr-81	1	16.600	71.000	26.9
	2	65.100	50.700	140.5
	3	47.200	49.100	218.5
May-81	1	26.000	41.400	156.5
	2	50.100	42.300	33.8
	3	0.700	0.000	0.0
.
.
.
Des-13	1	98.000	32.000	116.6
	2	211.600	148.600	142.4
	3	38.000	48.000	101.0

Lampiran 2

Matrix Partial Cross Correlation Function

[illegible]

Schematic Representation of Partial Cross Correlations

Variable/ Lag	169	170	171	172	173	174	175	176	177	178	179	180
y1
y2
y3

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 3

Estimasi Parameter Model VARIMA (2,0,0)(1,1,0)³⁶ Sebelum dilakukan *Restrict*

Model Parameter Estimates

Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
y1	AR1_1_1	0.00720	0.04491	0.16	0.8728	y1(t-1)
	AR1_1_2	0.07414	0.04806	1.54	0.1232	y2(t-1)
	AR1_1_3	0.03357	0.02430	1.38	0.1674	y3(t-1)
	AR2_1_1	-0.12077	0.04476	-2.70	0.0071	y1(t-2)
	AR2_1_2	0.16970	0.04729	3.59	0.0003	y2(t-2)
	AR2_1_3	0.05306	0.02431	2.18	0.0293	y3(t-2)
	AR36_1_1	-0.33667	0.04794	-7.02	0.0001	y1(t-36)
	AR36_1_2	-0.13976	0.05055	-2.76	0.0058	y2(t-36)
	AR36_1_3	-0.00284	0.02423	-0.12	0.9069	y3(t-36)
y2	AR1_2_1	0.02512	0.04155	0.60	0.5456	y1(t-1)
	AR1_2_2	0.04528	0.04446	1.02	0.3087	y2(t-1)
	AR1_2_3	0.04206	0.02248	1.87	0.0616	y3(t-1)
	AR2_2_1	-0.08975	0.04140	-2.17	0.0304	y1(t-2)
	AR2_2_2	0.09006	0.04374	2.06	0.0398	y2(t-2)
	AR2_2_3	0.05896	0.02249	2.62	0.0089	y3(t-2)
	AR36_2_1	0.20425	0.04435	4.61	0.0001	y1(t-36)
	AR36_2_2	-0.63931	0.04676	-13.67	0.0001	y2(t-36)
	AR36_2_3	0.01164	0.02241	0.52	0.6036	y3(t-36)
y3	AR1_3_1	0.03565	0.05387	0.66	0.5082	y1(t-1)
	AR1_3_2	0.05918	0.05764	1.03	0.3048	y2(t-1)
	AR1_3_3	0.08754	0.02915	3.00	0.0027	y3(t-1)
	AR2_3_1	-0.07577	0.05368	-1.41	0.1584	y1(t-2)
	AR2_3_2	0.03158	0.05672	0.56	0.5778	y2(t-2)
	AR2_3_3	0.13268	0.02915	4.55	0.0001	y3(t-2)
	AR36_3_1	0.16091	0.05750	2.80	0.0052	y1(t-36)
	AR36_3_2	-0.13511	0.06063	-2.23	0.0261	y2(t-36)
	AR36_3_3	-0.45686	0.02906	-15.72	0.0001	y3(t-36)

Lampiran 4

Program SAS Model VARIMA (2,0,0)(1,1,0)³⁶

```

data DASARIAN;
input y1 y2 y3;
datalines;
186.600 220.300 153.9
49.400          35.300          38.8
130.300 143.600 290.4
.          .          .
.          .          .
.          .          .
98.000          32.000          116.6
211.600 148.600 142.4
38.000          48.000          101.0
;
proc varmax data= DASARIAN printall;
model y1 y2 y3/ p=(1,2,36) dify=(36)
lagmax=108
minic=(p=10) noint
noint print=(corr pcorr);
    restrict AR(36,1,3)=0, AR(1,1,1)=0, AR(2,3,2)=0,
              AR(1,3,1)=0, AR(1,2,1)=0, AR(36,2,3)=0,
              AR(2,3,1)=0, AR(1,1,3)=0, AR(1,2,3)=0,
              AR(2,2,1)=0, AR(2,2,2)=0, AR(2,1,1)=0;
output lead=72 out=hasil;
run;
proc varmax data=hasil;
model RES1 RES2 RES3/ p=(1,2,36)
lagmax=108
minic=(p=10) noint
noint print=(corr pcorr);
run;
proc export data=WORK.hasil
outfile='D:\ModelVAR1.xls'
dbms=excel
replace;
run;

```

Lampiran 5

Program untuk Model VAR-SVR di Perak 1 dengan R

```
-----
#data keseluruhan
data.all=read.csv('D://VARSVR1.csv',
header=TRUE,check.names=FALSE)
n=dim(data.all)[1]
VAR.all=as.matrix(data.all)
x.all = VAR.all[,2:10]
y.all = VAR.all[,1]

-----

#data training
n.train = 1008
data.train = data.all[1:n.train,]
VAR1=as.matrix(data.train)
x.train = VAR1[,2:10]
y.train = VAR1[,1]

-----

#data testing
data.test = data.all[-(1:n.train),]
VAR=as.matrix(data.test)
x.test = VAR[,2:10]
y.test = VAR[,1]

-----

#Metode Grid Search Parameter Optimum
library(kernlab)
#VARSVR1
eps          = seq(0.000865,0.000869, by=0.0000001)
C            = seq(2270,2271, by=0.1)
sigma       = seq((0.00000012),(0.00000013), by=0.000000001)
```

Lampiran 5

Program untuk Model VAR-SVR di Perak 1 dengan R (Lanjutan)

```

nn                = length(eps)*length(C)*length(sigma)
err               = array(0, nn)
rmse.train       =array(0,nn)
rmse.test        =array(0,nn)
tab              = matrix(0,nn,6)

s=1
for(i in 1:length(eps))    {
  for(j in 1:length(C))    {
    for(k in 1:length(sigma)) {
      model.train =
ksvm(x.train,y.train,scaled=F,epsilon=eps[i],kpar=list(sigma=sigma[k]),
C=C[j]) err[s]=error(model.train)

      yhat.train   =predict(model.train,x.train)
      rmse.train[s] =sqrt(mean((yhat.train-y.train)^2))
      yhat.test    =predict(model.train,x.test)
      rmse.test[s]  =sqrt(mean((yhat.test-y.test)^2))
      s=s+1
    }
  }
}

s=1
for(i in 1:length(eps)){
  for(j in 1:length(C)){
    for(k in 1:length(sigma)){
      tab[s,1]=eps[i]
```


Lampiran 5

Program untuk Model VAR-SVR di Perak 1 dengan R (Lanjutan)

```

                                tab[s,2]=C[j]
                                tab[s,3]=sigma[k]
                                tab[s,4]=err[s]
                                tab[s,5]=rmse.train[s]
                                tab[s,6]=rmse.test[s]
                                s=s+1
                                }
                                }
                                }
colnames(tab)=c("epsilon", "cost", "sigma", "error", "RMSE-
train", "RMSE-test")
write.csv(tab, file="varsvr1.csv")

-----

#Mengurutkan nilai RMSE Testing Terkecil
sorttabel=tab[order(rmse.test),]
head(sorttabel)
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]

-----

#Mendapatkan Model Optimal
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]
model.optimal =
ksvm(x.train,y.train,scaled=F,epsilon=eps.optimal,kpar=list(sigma=sigm
a.optimal), C=C.optimal)

-----

#Prediksi data untuk data in-sample dan out-sample
```

Lampiran 5

Program untuk Model VAR-SVR di Perak 1 dengan R (Lanjutan)

```
yhat.train = predict(model.optimal,x.train)
```

```
yhat.test = predict(model.optimal,x.test)
```

Lampiran 6

Program untuk Model GSTAR-SVR Perak 1 dengan R

```
-----
```

```
#data keseluruhan
```

```
data.all=read.csv('D://GSTARSVR1.csv',
```

```
header=TRUE,check.names=FALSE)
```

```
n=dim(data.all)[1]
```

```
VAR.all=as.matrix(data.all)
```

```
x.all = GSTAR.all[,2:10]
```

```
y.all = GSTAR.all[,1]
```

```
-----
```

```
#data training
```

```
n.train = 972
```

```
data.train = data.all[1:n.train,]
```

```
VAR1=as.matrix(data.train)
```

```
x.train = GSTAR1[,2:10]
```

```
y.train = GSTAR1[,1]
```

```
-----
```

```
#data testing
```

```
data.test = data.all[-(1:n.train),]
```

```
VAR=as.matrix(data.test)
```

```
x.test = GSTAR[,2:10]
```

```
y.test = GSTAR[,1]
```

```
-----
```

```
#Metode Grid Search Parameter Optimum
```

```
library(kernlab)
```

Lampiran 6

Program untuk Model GSTAR-SVR Perak 1 dengan R (Lanjutan)

```
#GSTARSVR1
eps          = seq(0.00005,0.00009, by=0.00001)
C            = seq(350,355, by=0.1)
sigma        = seq(0.0000005,0.0000007, by=0.0000001)

nn           = length(eps)*length(C)*length(sigma)
err          = array(0, nn)
rmse.train   =array(0,nn)
rmse.test    =array(0,nn)
tab          = matrix(0,nn,6)

s=1
for(i in 1:length(eps))    {
  for(j in 1:length(C))    {
    for(k in 1:length(sigma)) {
      model.train =
ksvm(x.train,y.train,scaled=F,epsilon=eps[i],kpar=list(sigma=sigma[k]),
C=C[j]) err[s]=error(model.train)

yhat.train      =predict(model.train,x.train)
rmse.train[s]   =sqrt(mean((y.train-fitted(model.train))^2))
yhat.test       =predict(model.train,x.test)
rmse.test[s]    =sqrt(mean((yhat.test-y.test)^2))
      s=s+1
    }
  }
}
```

Lampiran 6

Program untuk Model GSTAR-SVR Perak 1 dengan R (Lanjutan)

```
s=1
```

```
for(i in 1:length(eps)){
```

```
  for(j in 1:length(C)){
```

```
    for(k in 1:length(sigma)){
```

```
      tab[s,1]=eps[i]
```

```
      tab[s,2]=C[j]
```

```
      tab[s,3]=sigma[k]
```

```
      tab[s,4]=err[s]
```

```
      tab[s,5]=rmse.train[s]
```

```
      tab[s,6]=rmse.test[s]
```

```
      s=s+1
```

```
    }
```

```
  }
```

```
}
```

```
colnames(tab)=c("epsilon","cost","sigma","error","RMSE-  
train","RMSE-test")
```

```
write.csv(tab,file="GSTARSVR1.csv")
```

```
-----  
#Mengurutkan nilai RMSE Testing Terkecil
```

```
sorttabel=tab[order(rmse.test),]
```

```
head(sorttabel)
```

```
eps.optimal      = sorttabel[1,1]
```

```
C.optimal        = sorttabel[1,2]
```

```
sigma.optimal    = sorttabel[1,3]
```

```
-----  
#Mendapatkan Model Optimal
```

```
eps.optimal      = sorttabel[1,1]
```

```
C.optimal        = sorttabel[1,2]
```

```
sigma.optimal    = sorttabel[1,3]
```

Lampiran 6

Program untuk Model GSTAR-SVR Perak 1 dengan R (Lanjutan)

```
model.optimal =
ksvm(x.train,y.train,scaled=F,epsilon=eps.optimal,kpar=list(sigma=sigm
a.optimal), C=C.optimal)
```

#Prediksi data untuk data *in-sample* dan *out-sample*

```
yhat.train = predict(model.optimal,x.train)
```

```
yhat.test = predict(model.optimal,x.test)
```

Lampiran 7

Program SAS untuk Model GSTAR Bobot Seragam dengan
Semua Parameter

```
data GSTARSERAGAM;
  input y1t    y2t    y3t    y1t1    y2t1    y3t1    y1t2
        y2t2    y3t2    y1t36   y2t36   y3t36   y1t72   y2t72
        y3t72    y1t108  y2t108  y3t108  y1t144  y2t144  y3t144
        y1t180  y2t180  y3t180  v1t1    v2t1    v3t1    v1t2
        v2t2    v3t2    v1t36   v2t36   v3t36   v1t72   v2t72
        v3t72    v1t108  v2t108  v3t108  v1t144  v2t144  v3t144
        v1t180  v2t180  v3t180;
datalines;
-3.200  -78.500  34.2    17.100  26.800  -75.2    169.000  127.700
        -26.5    18.500  52.8    193.3   -67.20  -32.9    -157.9
        94.40    57.1    90.3    -115.90 -114.6   -48.1    -36.40
        -43.6    -21.8    -24.200 -29.050  21.950  50.600  71.250
        148.350  123.05   105.900 35.650  -95.40  -112.550 -50.050
        73.70    92.350  75.750  -81.35  -82.000 -115.250 -32.70
        -29.100  -40.000
        .        .        .        .        .        .        .
        .        .        .        .        .        .        .
        .        .        .        .        .        .        .
-98.300  -94.000  57.9    168.000  62.600  57.3    71.500  -57.900
        73.8    1.400  -0.1    -135.6  77.50  83.8    130.8
        35.90  46.9    -11.2   -47.20  -75.5   33.9    -24.70
        -13.8   -75.5   59.950  112.650  115.300  7.950  72.650
        6.800   -67.85  -67.100  0.650  107.30  104.150  80.650
        17.85  12.350  41.400  -20.80  -6.650  -61.350  -44.65
        -50.100 -19.250
;
```

Lampiran 7

Program SAS untuk Model GSTAR Bobot Seragam dengan Semua Parameter (Lanjutan)

```
proc syslin data=GSTARSERAGAM out=HASIL sur;
y1: model y1t=y1t1 y1t2 y1t36 y1t72 y1t108 y1t144 y1t180 v1t1 v1t2
v1t36 v1t72 v1t108 v1t144 v1t180/noint;
output p=Pred_y1 r=res_y1;
y2: model y2t=y2t1 y2t2 y2t36 y2t72 y2t108 y2t144 y2t180 v2t1 v2t2
v2t36 v2t72 v2t108 v2t144 v2t180/noint;
output p=Pred_y2 r=res_y2;
y3: model y3t=y3t1 y3t2 y3t36 y3t72 y3t108 y3t144 y3t180 v3t1 v3t2
v3t36 v3t72 v3t108 v3t144 v3t180/noint;
output p=Pred_y3 r=res_y3;
run;
proc export data=HASIL
outfile='D:\ModelGSTARSeragam.xls'
dbms=excel
replace;
run;
```

Lampiran 8

Program SAS untuk Model GSTAR Bobot Seragam dengan Parameter Signifikan

```
data GSTARSERAGAM;
  input y1t    y2t    y3t    y3t1    y3t2    y1t36    y2t36
        y3t36    y1t72    y2t72    y3t72    y1t108    y2t108    y3t108
        y1t144    y2t144    y3t144    y1t180    y2t180    y3t180    v1t1
        v2t1    v3t2    v2t36    v1t108    v1t180    v3t180;
datalines;
```

-3.2	-78.5	34.2	-75.2	-26.5	18.5	52.8	193.3
	-67.2	-32.9	-157.9	94.4	57.1	90.3	-115.9
	-114.6	-48.1	-36.4	-43.6	-21.8	-24.2	-29.05
	148.35	105.9	73.7	-32.7	-40		
.
.
.
168	62.6	57.3	73.8	41.4	-107.7	-149.7	-32.1
	99.5	202.4	69.5	-48.6	-59.1	-57.3	-137.5
	-88.9	-227.4	103.9	48.4	283.9	7.95	72.65
	-11.85	-69.9	-58.2	166.15	76.15		
-98.3	-94	57.9	57.3	73.8	1.4	-0.1	-135.6
	77.5	83.8	130.8	35.9	46.9	-11.2	-47.2

Lampiran 8

Program SAS untuk Model GSTAR Bobot Seragam dengan Parameter Signifikan (Lanjutan)

```

-75.5    33.9    -24.7    -13.8    -75.5    59.95    112.65
 6.8     -67.1    17.85   -44.65   -19.25
;
proc syslin data=GSTARSERAGAM out=HASIL sur;
y1: model y1t=y1t36 y1t72 y1t108 y1t144 y1t180 v1t1 v1t108
v1t180/noint;
output p=pred_y1 r=res_y1;
y2: model y2t=y2t36 y2t72 y2t108 y2t144 y2t180 v2t1 v2t36/noint;
output p=pred_y2 r=res_y2;
y3: model y3t=y3t1 y3t2 y3t36 y3t72 y3t108 y3t144 y3t180 v3t2
v3t180/noint;
output p=pred_y3 r=res_y3;
run;
proc export data=HASIL
outfile='D:\GSTARSeragamRest.xls'
dbms=excel
replace;
run;

```

Lampiran 9

Hasil Estimasi Model GSTAR Bobot Seragam dengan Semua Parameter

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1t1	1	0.036959	0.023211	1.59	0.1117
y1t2	1	0.009620	0.023163	0.42	0.6780
y1t36	1	-0.84377	0.031086	-27.14	<.0001
y1t72	1	-0.73916	0.039161	-18.87	<.0001
y1t108	1	-0.59344	0.042252	-14.05	<.0001
y1t144	1	-0.38437	0.040518	-9.49	<.0001
y1t180	1	-0.24612	0.031492	-7.82	<.0001
v1t1	1	0.090124	0.028670	3.14	0.0017
v1t2	1	0.052689	0.028695	1.84	0.0666
v1t36	1	0.104504	0.037508	2.79	0.0054
v1t72	1	0.094306	0.047238	2.00	0.0462
v1t108	1	0.187515	0.052166	3.59	0.0003
v1t144	1	0.101041	0.049569	2.04	0.0418
v1t180	1	0.114379	0.038737	2.95	0.0032

Lampiran 9

Hasil Estimasi Model GSTAR Bobot Seragam dengan Semua Parameter (Lanjutan)

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y2t1	1	0.002207	0.022902	0.10	0.9233
y2t2	1	-0.02122	0.022574	-0.94	0.3475
y2t36	1	-0.85682	0.030229	-28.34	<.0001
y2t72	1	-0.74770	0.038361	-19.49	<.0001
y2t108	1	-0.57783	0.041070	-14.07	<.0001
y2t144	1	-0.38330	0.038620	-9.92	<.0001
y2t180	1	-0.22808	0.030211	-7.55	<.0001
v2t1	1	0.095705	0.025843	3.70	0.0002
v2t2	1	0.064048	0.025784	2.48	0.0132
v2t36	1	0.110538	0.033159	3.33	0.0009
v2t72	1	0.058108	0.041335	1.41	0.1601
v2t108	1	0.097197	0.044108	2.20	0.0278
v2t144	1	0.061627	0.041674	1.48	0.1395
v2t180	1	0.042881	0.033130	1.29	0.1959

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y3t1	1	0.091871	0.025827	3.56	0.0004
y3t2	1	0.106184	0.025886	4.10	<.0001
y3t36	1	-0.74559	0.032774	-22.75	<.0001
y3t72	1	-0.62083	0.040657	-15.27	<.0001
y3t108	1	-0.41069	0.043835	-9.37	<.0001
y3t144	1	-0.28582	0.041043	-6.96	<.0001
y3t180	1	-0.13763	0.032613	-4.22	<.0001
v3t1	1	0.066187	0.035263	1.88	0.0608
v3t2	1	-0.07056	0.035173	-2.01	0.0451
v3t36	1	0.002426	0.044923	0.05	0.9569
v3t72	1	-0.04230	0.055331	-0.76	0.4448
v3t108	1	0.022274	0.059688	0.37	0.7091
v3t144	1	-0.00853	0.055645	-0.15	0.8781
v3t180	1	-0.08680	0.043845	-1.98	0.0480

Lampiran 10

Hasil Estimasi Model GSTAR Bobot Seragam dengan Parameter Signifikan

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1t36	1	-0.81810	0.026303	-31.10	<.0001
y1t72	1	-0.70134	0.031523	-22.25	<.0001
y1t108	1	-0.56707	0.036033	-15.74	<.0001
y1t144	1	-0.34766	0.032201	-10.80	<.0001
y1t180	1	-0.23321	0.028578	-8.16	<.0001
v1t1	1	0.105488	0.025126	4.20	<.0001
v1t108	1	0.062066	0.025331	2.45	0.0145
v1t180	1	0.061079	0.025731	2.37	0.0178

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y2t36	1	-0.85426	0.027128	-31.49	<.0001
y2t72	1	-0.73089	0.031345	-23.32	<.0001
y2t108	1	-0.55716	0.034794	-16.01	<.0001
y2t144	1	-0.36857	0.032229	-11.44	<.0001
y2t180	1	-0.21718	0.026401	-8.23	<.0001
v2t1	1	0.087419	0.022079	3.96	<.0001
v2t36	1	0.050656	0.022054	2.30	0.0218

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y3t1	1	0.111252	0.024044	4.63	<.0001
y3t2	1	0.090366	0.024982	3.62	0.0003
y3t36	1	-0.77961	0.028671	-27.19	<.0001
y3t72	1	-0.66093	0.035276	-18.74	<.0001
y3t108	1	-0.44589	0.038582	-11.56	<.0001
y3t144	1	-0.31639	0.036013	-8.79	<.0001
y3t180	1	-0.15513	0.030668	-5.06	<.0001
v3t2	1	-0.08164	0.033142	-2.46	0.0139
v3t180	1	-0.09086	0.034306	-2.65	0.0082

Lampiran 11**Output Uji Normalitas Model VAR**

```
> mvShapiro.Test(RESI1)
```

```
Generalized Shapiro-Wilk test for Multivariate Normality
```

```
data: RESI1
```

```
MVW = 0.89979, p-value = 2.414e-10
```

```
> mvShapiro.Test(RESI2)
```

```
Generalized Shapiro-Wilk test for Multivariate Normality
```

```
data: RESI2
```

```
MVW = 0.91381, p-value = 6.835e-09
```

```
> mvShapiro.Test(RESI3)
```

```
Generalized Shapiro-Wilk test for Multivariate Normality
```

```
data: RESI3
```

```
MVW = 0.91685, p-value = 1.449e-08
```

```
> mvShapiro.Test(RESI4)
```

```
Generalized Shapiro-Wilk test for Multivariate Normality
```

```
data: RESI4
```

```
MVW = 0.91996, p-value = 3.167e-08
```

```
> mvShapiro.Test(RESI5)
```

```
Generalized Shapiro-Wilk test for Multivariate Normality
```

```
data: RESI5
```

```
MVW = 0.9158, p-value = 1.115e-08
```

Lampiran 12**Output Uji Normalitas Model GSTAR dengan Parameter Signifikan**

```
Generalized Shapiro-Wilk test for Multivariate Normality

data:  resi1
MVW = 0.8789, p-value < 2.2e-16

> mvShapiro.Test(resi2)

Generalized Shapiro-Wilk test for Multivariate Normality

data:  resi2
MVW = 0.8771, p-value < 2.2e-16

> mvShapiro.Test(resi3)

Generalized Shapiro-Wilk test for Multivariate Normality

data:  resi3
MVW = 0.8798, p-value < 2.2e-16
```

Lampiran 13

Data untuk Model VAR-SVR di Perak 1 Keseluruhan

No	$y_1(t)$	$y_1(t-1)$	$y_1(t-2)$	$y_2(t-2)$	$y_3(t-2)$	$y_1(t-36)$	$y_1(t-72)$	$y_1(t-108)$	$y_2(t-108)$	$y_1(t-144)$
1	18.5	51.1	-22.6	-15	55.7	-67.2	94.4	-115.9	-114.6	-36.4
2	-158.1	18.5	51.1	31.3	-58.7	60.5	-2	40.3	45	48.3
3	153.4	-158.1	18.5	52.8	193.3	-126	167.5	-97.4	-91.3	13.1
.
.
.
1073	0	0	0	0	0	0	-2.8	2.8	0	-167
1074	-8	0	0	0	0	2	-48.5	31.9	21.8	4.5
1075	74	-8	0	0	0	-7	4	-138.5	-99.9	108.4

Lampiran 14

Data untuk Model GSTAR-SVR di Perak 1 Keseluruhan

No	$y_1(t)$	$y_1(t-36)$	$y_1(t-72)$	$y_1(t-108)$	$y_1(t-144)$	$y_1(t-180)$	$v_1(t-1)$	$v_1(t-2)$	$v_1(t-108)$	$v_1(t-180)$
1	-3.2	18.5	-67.2	94.4	-115.9	-36.4	-22.3281	75.59905	89.82817	-42.7302
2	27.6	-158.1	60.5	-2	40.3	48.3	-36.6496	-22.3281	-75.2465	130.6776
3	-47.3	153.4	-126	167.5	-97.4	13.1	37.13015	-36.6496	227.9979	-99.1857
.
.
.
1037	0	0	-2.8	2.8	-167	167	0	0	1.151764	167.0931
1038	-8	2	-48.5	31.9	4.5	18.1	0	0	10.06682	51.96396
1039	74	-7	4	-138.5	108.4	35.1	0	0	-123.822	55.15154

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis bernama Feby Sandi Nabila, merupakan anak dari pasangan Sugeng Irianto dan Dwi Puryanu. Penulis merupakan anak kedua dari 2 bersaudara yang dilahirkan di Sidoarjo pada tanggal 06 Februari 1994. Penulis memulai jenjang pendidikan yang pertama di Taman Kanak-kanak Dharma Wanita Balontani (1999-2000), kemudian melanjutkan di SDN Balongtani (2000-2006). Setelah menamatkan pendidikan madrasah ibtidaiah penulis melanjutkan pendidikan di SMP Negeri 1 Porong (2006-2008) dan di SMA Negeri 3 Sidoarjo (2009-2012). Pada tahun 2012, penulis diterima di Perguruan Tinggi Negeri ITS melalui jalur tes SNMPTN Tulis dan diterima sebagai mahasiswi Jurusan Statistika dengan NRP 1312100072. Selama kuliah penulis aktif dalam kegiatan organisasi Koperasi Mahasiswa Dr. Angka ITS, Kewirausahaan HIMASTA ITS, Badan Eksekutif Mahasiswa FMIPA ITS, dan beberapa kegiatan kepanitiaan seperti Gerigi ITS 2013, GEMPA 3.0, 4.0, dll. Penulis pernah berkesempatan menjadi salah satu tim PIMNAS 28 Unhalu Kendari dan berhasil meraih medali perak presentasi.

Penulis menerima segala kritikan, masukan, dan saran yang bersifat membangun demi meningkatkan manfaat Tugas Akhir ini. Oleh karena itu, penulis siap membantu terkait dengan metode dan ilmu statistik, jika dibutuhkan pembaca dapat menghubungi penulis melalui email : febysnabila@gmail.com.

(Halaman ini sengaja dikosongkan)